

VŠB-Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

**Analýza medicínských snímků za účelem rekonstrukce
objektu na snímku k následnému zpracování**

**The Analysis of Medical Images in Order to
Reconstruct the Object in the Image for Subsequent
Processing**

2013

Bc. Jan Tomeček

VŠB - Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Zadání diplomové práce

Student: **Bc. Jan Tomeček**

Studijní program: N2649 Elektrotechnika

Studijní obor: 3901T009 Biomedicínské inženýrství

Téma: **Analýza medicínských snímků za účelem rekonstrukce objektu
na snímku k následnému zpracování**
**The Analysis of Medical Images in Order to Reconstruct the Object
in the Image for Subsequent Processing**

Zásady pro vypracování:

Analýza medicínských snímků za účelem rekonstrukce objektu na snímku k následnému zpracování.

Cílem práce je návrh a realizace modulu systému FOTOM, který umožní nalezení a případnou rekonstrukci objektu na snímku k následnému zpracování.

1. Nastudování základních postupů vhodných ke zpracování uvedených typů snímků.
2. Seznámení se s prostředím NetBeans a programovacím jazykem JAVA.
3. Seznámení se s fotogrammetrickým systémem FOTOM.
4. Implementace požadované funkcionality pomocí jazyka JAVA a její začlenění do tohoto systému.
5. Demonstrace funkčnosti na poskytnutých snímcích.
6. Zpracování programátorské i uživatelské příručky a zhodnocení dosažených výsledků.

Seznam doporučené odborné literatury:

- [1] GONZALEZ, C. Rafael a E. Richard WOODS. *Digital Image Processing*. 3rd Edition. Upper Saddle River(USA):Pearson Prentice Hall, 2008. 954 s. ISBN 978-0-13-168728-8.
- [2] RUSS, John C. *The Image Processing Handbook*. 5th Edition. Boca Raton(USA): CRC/Taylor & Francis, c2007. 817 s. ISBN 0-8493-7254-2.
- [3] LIČEV, Lačezar. *Analýza, modelování, rozpoznávání a vizualizace procesu měření objektů na snímcích*. 1.vyd. Brno: Computer Press, a.s., 2010. 128 s. ISBN 978-80-2513-296-8, EAN 9788025132968. Knihy vydané prostřednictvím www.vydejteknihu.cz.
- [4] LIANG, Daniel Y. *Introduction to Java Programming, Comprehensive*. 8 edition. Upper Saddle River(USA):Prentice Hall, 2010. ISBN-13: 978-0132130806.
- [5] SOJKA, Eduard. *Digitální zpracování a analýza obrazů*. 1.vyd. Ostrava:VŠB - TU Ostrava, 2000. ISBN 80-7078-746-5.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.


Vedoucí diplomové práce: **doc. Ing. Lačezar Ličev, CSc.**

Datum zadání: 16.11.2012

Datum odevzdání: 07.05.2013



doc. Ing. Jiří Koziorek, Ph.D.
vedoucí katedry



prof. RNDr. Václav Snášel, CSc.
děkan fakulty

Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně.

Uvedl jsem všechny použité literární zdroje a publikace, ze kterých jsem čerpal.



.....
Jan Tomeček

Datum odevzdání diplomové práce: 7.5.2013

Poděkování

Tímto bych chtěl poděkovat svému vedoucímu práce doc.Ing. Lačezaru Ličevovi, CSc za ochotné a trpělivé vedení této práce a za jeho užitečné rady a připomínky. Dále patří moje poděkování Ing. Tomáši Fabiánovi za cenné rady zejména v problematice aktivních kontur.

Abstrakt

Tato práce se zabývá metodami analýzy a zpracování medicínských obrazů, a jejich využitím při rekonstrukci objektu karotické tepny na ultrazvukových snímcích v B-zobrazení, příčném řezu. Cílem je navrhnout metodu pro automatickou a poloautomatickou detekci vnitřní stěny tepny a následně tyto postupy implementovat v jazyce Java do fotogrammetrického systému FOTOM^{NG}, který je postaven na modulární platformě NetBeans. Pozornost je zaměřena především na filtraci ultrazvukových snímků a metody aktivních kontur, a to ať už parametrických, tak geometrických. Navržený algoritmus dále využívá Houghovu transformaci a gradientní vektorový tok (GVF) jako vnější sílu působící na deformovatelné modely. Díky integraci nástroje do systému FOTOM^{NG} je možné detekované objekty ihned kvantitativně analyzovat, čímž může být výrazně usnadněna práce vyšetřujícího lékaře.

Klíčová slova

FOTOM, zpracování obrazu, ateroskleróza, aktivní kontury, gradientní vektorový tok, Chan Vese, speckle šum, anizotropní difuze, Houghova transformace, NetBeans, Java, JAI.

Abstract

This study deals with the methods of analysis and processing of medical images and their use at the reconstruction of the carotide artery at the ultrasound images in B-mode, transversal section. The aim of this study is to project the methods for automatic and semiautomatic detection of the inner artery wall and to implement these procedures subsequently in the Java language to the fotogrammetric system FOTOM^{NG}, which is built on the NetBeans modular platform. The attention is paid mainly on the filtering of the ultrasound images and the active contours methods, both parametric and geometric. Designed algorithm then uses the Hough transform and gradient vector flow (GVF) as an external forces that affect the deformable models. Thanks to the tool integration to the FOTOM^{NG} system, this is possible to make the quantitative analysis of the detected objects immediately, thus to be able of facilitate markedly the work of the physician.

Key Words

FOTOM, image processing, atherosclerosis, active contours, gradient vector flow, Chan Vese, speckle noise, anisotropic diffusion, Hough transform, NetBeans, Java, JAI.

Seznam použitých symbolů a zkratek

AD	Analogově digitální převodník
AHE	Adaptivní ekvalizace histogramu
API	Application Programming Interface
CLAHE	Kontrastně limitovaná adaptivní ekvalizace histogramu
CT	Výpočetní tomografie
EKG	Elektokardiogram, elektrokardiograf
GVF	Gradientní vektorový tok
JAI	Java advanced imaging
MAE	Střední absolutní odchylka
MRI	Magnetická rezonance
PSNR	Špičkový poměr signálu k šumu
RF	Radiofrekvenční
RMSE	Root mean square error
SAR	Radar se syntetickou aperturou
SNR	Poměr signálu k šumu
SRAD	Speckle redukující anizotropně difuzní
TGC	Time gain compensation
VŠB-TU	Vysoká škola báňská Technická univerzita

Obsah

1	Úvod.....	1
2	Krční tepna a ateroskleróza.....	2
2.1	Diagnostické metody.....	2
2.2	Dělení sklerotických plátů.....	2
3	Princip diagnostického ultrazvuku.....	4
3.1	Interakce a šíření ultrazvukové vlny v lidském těle.....	4
3.1.1	Rychlost šíření.....	4
3.1.2	Odraz a lom ultrazvukové vlny.....	4
3.1.3	Útlum ultrazvukové vlny.....	7
3.2	Generování a zpracování ultrazvukového signálu.....	8
3.2.1	Generování pulsu.....	8
3.2.2	Zesílení, TGC.....	9
3.2.3	AD převodník.....	9
3.2.4	Detekce obálky.....	9
3.2.5	Logaritmická komprese.....	11
3.3	Speckle.....	11
3.4	Artefakty.....	13
4	Zpracování obrazu.....	14
4.1	Filtry odstraňující speckle šum.....	14
4.1.1	Statistické filtry.....	14
4.1.2	Difuzní filtry.....	15
4.1.3	Mediánový filtr.....	19
4.1.4	Mean-shift filtr.....	19
4.2	Ekvalizace histogramu.....	21
4.2.1	Adaptivní ekvalizace histogramu (AHE).....	22
4.2.2	Omezení kontrastu (CLAHE).....	22
4.3	Houghova transformace.....	23
4.3.1	Detekce kružnic.....	24
4.3.2	Zobecněná Houghova transformace.....	25
4.4	Parametrické aktivní kontury.....	26
4.4.1	Vnitřní síly.....	26

4.4.2	Vnější síly	27
4.4.3	Implementace	28
4.5	Gradientní vektorový tok	30
4.5.1	Implementace	31
4.6	Geometrické aktivní kontury - Chan Vese	32
4.6.1	Level set	33
4.6.2	Chan Vese	34
4.6.3	Implementace	35
5	FOTOM	38
6	Návrh a realizace	39
6.1	Automatická detekce	39
6.1.1	Akvizice	39
6.1.2	Úprava kontrastu	41
6.1.3	Filtrace	42
6.1.4	Detekce hran a prahování	45
6.1.5	Houghova transformace	45
6.1.6	Rekonstrukce stěn tepny	46
6.1.7	Segmentace	47
6.2	Poloautomatická detekce	49
6.3	Tvorba 3D modelu	49
6.4	Zařazení do systému FOTOM ^{NG}	50
7	Výsledky	53
7.1	Automatická detekce tepny	53
7.2	Segmentace při automatické a poloautomatické detekci	55
8	Závěr	57
9	Použitá literatura	59
10	Seznam příloh	62
10.1	Přílohy uložené na CD	62

1 Úvod

Třetí nejčastější příčinou úmrtí v naší populaci je cévní mozková příhoda. Konkrétně ischemická cévní mozková příhoda tvoří největší skupinu těchto onemocnění. I přes veškerý pokrok v terapeutických metodách medicíny, doposud nebyla nalezena metoda, která by spolehlivě snižovala mortalitu této choroby. Hlavním způsobem boje s touto nemocí tak zůstává prevence. Jelikož častou příčinou ischemické cévní mozkové příhody jsou aterosklerotické pláty v karotické tepně, jejich zkoumáním lze určit vývoj onemocnění.

Cílem této práce je navrhnout a realizovat modul fotogrammetrického systému FOTOM^{NG}, který usnadní vyšetření karotické tepny z ultrazvukových snímků. Snímky budou získávány ze zařízení pro 3D ultrazvukové vyšetření, které bylo vyvinuto na VŠB-TU Ostrava v minulých letech. Navržený algoritmus bude schopen sám nalézt objekt krční tepny na snímku a následně označit vnitřní část arterie s případným zúžením. Mimo vnitřní část bude také označen obrys tepny bez plátů, s možností označené oblasti dále v systému FOTOM^{NG} jednotlivě nebo vůči sobě proměřovat. Cílem je realizovaný modul do programu integrovat tak, aby jeho využití bylo z uživatelského pohledu co nejsnadnější a dále aby využíval dosavadní způsob definice objektů, pro možnou další analýzu a serializaci v systému. Současně je úkolem této práce také vypracovat programátorskou a uživatelskou příručku.

Ačkoliv se práce zabývá hlavně zpracováním ultrazvukových snímků (B-zobrazení) a analýzou karotické tepny, navržené a realizované nástroje budou použitelné pro rekonstrukci objektů na široké škále medicínských obrazů získaných z různých modalit. Bude tak dodržena i jistá obecnost v názvu práce.

V následující kapitole (kap. 2) bude nastíněna problematika aterosklerózy a vyšetření karotických tepen.

Další kapitola (kap. 3) se bude zabývat principem diagnostického ultrazvuku, interakce ultrazvukového vlnění s lidskou tkání a následný projev těchto interakcí na získané obrazové funkci. Hlavní pozornost bude patřit zejména vzniku tzv. speckle šumu a jeho chování v rámci dalšího zpracování přijatého ultrazvukového signálu v ultrasonografu.

Následující část (kap. 4) poté bude patřit metodám zpracování obrazu využívaným v této práci. Popisované metody jsou zvoleny zejména s ohledem na charakter ultrazvukových snímků a jejich specifické vlastnosti.

V kapitole č.5 bude popsán systém FOTOM a jeho postupný vývoj v minulých letech.

Srovnáním jednotlivých metod zpracování obrazu a popisem návrhu postupu pro automatickou a poloautomatickou detekci a rekonstrukci objektu karotické tepny se bude zabývat kapitola č.6.

Sedmá kapitola se nakonec věnuje výsledkům testování realizovaných nástrojů.

2 Krční tepna a ateroskleróza

Krční tepna (*arteria carotis communis*) je párová tepna, která přivádí krev do hlavy a částečně i krku. Karotické tepny jsou uloženy relativně povrchově na krku a pomocí jejich nahmatání jde kontrolovat tep. Díky jejich snadnému přístupu slouží také k dále popsanému vyšetření stavu tepen. Levá společná karotida vychází z oblouku aorty, pravá z hlavopažního kmene. Pravá i levá společná karotida se v oblasti krku větví na vnější karotidu (*arteria carotis externa*), která mimo mozků zásobuje části hlavy uložené vně lebky, ale i svaly krku. Vnitřní karotida (*arteria carotis interna*) přivádí krev do mozku, ale také např. do očních bulv, očních víček, kůže čela, a dalších [1].

Karotické tepny často podléhají zužování, zejména díky ateroskleróze. Aterosklerózu lze řadit mezi civilizační choroby. Jedná se o kornatění tepen, kdy jsou ve stěně tepny ukládány tukové látky. Průběh aterosklerózy lze rozdělit do několika fází. Nejprve jsou ve stěně tepny přítomna lipidní ložiska. Následně tato ložiska vystoupí na povrch stěny tepny, kdy vzniká ateromový plát. Pokud se plát rozpadne, mastný obsah se vyplaví do krve, a na místě vznikne ateromový vřed a s tím i trombus, který zužuje tepnu. Nakonec začne postižená část kalcifikovat a ložisko tvrdne. Uvolněný trombus může způsobit ischemickou cévní mozkovou příhodu. Zúžení tepen má také za následek omezení průtoku krve do mozku. Cévní mozková příhoda je na třetím místě v nejčastější příčině úmrtí v této populaci, kdy 85% z tohoto množství tvoří právě ischemická cévní mozková příhoda. Jelikož dosud neexistuje účinná metoda léčby akutní ischemické mozkové příhody, je velmi důležitá prevence tohoto stavu. Právě ateromatóza karotických tepen bývá nejčastějším etiologickým faktorem tohoto onemocnění [2], [3].

2.1 Diagnostické metody

K vyšetření karotické tepny se díky dostupnosti, neinvazivnosti a možné opakovatelnosti používá nejčastěji duplexní ultrasonografie. Nevýhoda této metody spočívá v omezené délce tepny, kterou lze vyšetřovat, a dále často subjektivní vyhodnocování lékařem. Pro měření průtoku krve tepnou se používají dopplerovské metody, z kterých lze určit i redukci průměru lumina. Pro hodnocení aterosklerotických změn, i v případě, že ještě nedošlo ke stenóze, a dále struktury sklerotických plátů, se však stále používá B-zobrazení.

Kromě ultrasonografií lze pro vyšetření karotických tepen použít i tomografické metody, jako jsou CT a MRI, čímž se zvětší i rozsah vyšetřované oblasti tepny. Nevýhodou je však časová náročnost, menší dostupnost, a v případě CT vystavení pacienta radiační zátěži.


Další možností vyšetření krčních tepen je *digitální subtrakční angiografie*, kde se dosahuje velmi kvalitního zobrazení. Hlavní nevýhodou je invazivnost metody.

2.2 Dělení sklerotických plátů

Pláty lze dělit podle několika hledisek. Podle struktury je lze klasifikovat jako homogenní a heterogenní, kdy hlavními znaky pro toto rozdělení jsou rozdíly textury ateromatózních hmot, které mají nízkou echogenitu. Povrch plátů lze poté hodnotit jako hladký,

nepravidelný a ulcerovaný. Dalším kritériem je echogenita plátů v celém rozsahu odrazivosti založená na stupni kalcifikace plátů. Při vyšetření se hodnotí také rozsah a poloha plátu.

Homogenní pláty se vyznačují jednotnou středně vysokou až vysokou echogenitou a hladkým povrchem. Tyto pláty jsou většinou stabilní. Heterogenní pláty se objevují častěji v pokročilejším stádiu aterosklerotického poškození tepny, mají ulcerovaný povrch a statisticky zvyšují riziko cévní mozkové příhody. Kalcifikace může být přítomna jak u homogenních, tak heterogenních plátů.



Obrázek 1 Karotická tepna s postupným vývojem plátu [43]

3 Princip diagnostického ultrazvuku

Pro zvolení vhodných metod pro zpracování lékařského snímku je nejprve potřeba pochopit, jak snímek vzniká, a jaké jsou jeho vlastnosti. Ultrazvuk je mechanické vlnění, jehož frekvenční spektrum leží mezi 20 kHz až 1 GHz. Pro aplikaci v lékařství se používají nejčastěji frekvence od 2 do 30 MHz. Po vhodném vybuzení piezoelektrických měničů sondy je do těla pacienta vyslána podélná ultrazvuková vlna. Tím, jak se vlna šíří v těle pacienta, mění se její směr šíření a intenzita. V jednotlivých orgánech a na rozhraních mezi jednotlivými orgány se část vlny tkání pohltí, část odrazí a část rozptýlí. Při použití reflexní metody, která se používá při běžném diagnostickém vyšetření, se zachytí odražené vlny, které dopadnou na piezoelektrické snímače sondy, a z vlastností takto modulovaných vln je odvozena informace o zkoumané tkáni. Dále popsané interakce ultrazvukových vln s tkáněmi jsou velmi významné pro pochopení vzniku zejména artefaktů, které znesnadňují další analýzu obrazu. Se znalostí vzniku a povahy artefaktů lze vybrat vhodné algoritmy pro analýzu daných snímků [5].

3.1 Interakce a šíření ultrazvukové vlny v lidském těle

3.1.1 Rychlost šíření

Rychlost šíření ultrazvukové vlny se mění v závislosti na prostředí, ve kterém se vlna šíří. V prostředí s větší hustotou, tedy například v pevných látkách, se vlna šíří rychleji, než například v plynech. Pro diagnostické ultrazvukové přístroje, sloužící k vyšetřování měkkých tkání, je uvažována jednotná rychlost šíření vlny, a to 1540 m/s. Rychlost v měkkých tkáních se ve skutečnosti pohybuje mezi 1450 m/s až 1560 m/s. Díky této aproximaci je velmi usnadněno zpracování přijatých vln, jelikož jde provést lineární transformaci mezi prostorem a časem. Podle zpoždění mezi vyslanou a odraženou vlnou lze tedy určit hloubku, ve které došlo k odrazu [5].

3.1.2 Odraz a lom ultrazvukové vlny.

3.1.2.1 Spekulární odraz

Spekulární odraz nastává na rozhraní mezi dvěma objekty s rozdílnými akustickými vlastnostmi za předpokladu, že je objekt, na který vlna dopadla, mnohem větší, než je vlnová délka ultrazvukové vlny. Pokud je uvažován kolmý dopad na objekt, část vlny projde do následujícího orgánu a část se odrazí zpět k sondě, již však s menší amplitudou. Tkáň, obecně médium, ve kterém se vlna šíří, je dána určitou akustickou impedancí Z . Rozdíl akustických impedancí mezi jednotlivými tkáněmi je primárním parametrem ultrazvukovým zobrazovacích systémů. Platí, že

$$Z = \rho \cdot c \text{ [Pa} \cdot \text{s} \cdot \text{m}^{-1}] \quad (1)$$

kde $c[\text{m} \cdot \text{s}^{-1}]$ je rychlost šíření ultrazvukové vlny a $\rho[\text{Pa}]$ je hustota dané tkáně. Amplitudový reflexní koeficient je potom dán


$$r_a = \frac{A_r}{A_o} = \frac{Z_1 - Z_2}{Z_1 + Z_2} \quad (2)$$

kde A_o je amplituda původní vlny, A_r je amplituda odražené vlny, $Z_1[Pa \cdot s \cdot m^{-1}]$ je akustická impedance dosavadního prostředí, $Z_2[Pa \cdot s \cdot m^{-1}]$ je akustická impedance prostředí, do kterého vlna vstupuje. Pro názornost je uvažována koule, jejíž poloměr je mnohem větší než vlnová délka vlny (obr. 2), tedy $k \cdot a \gg 1$, kde

$$k = \frac{2 \cdot \pi}{\lambda} \quad (3)$$

zde, $\lambda[m]$ je vlnová délka ultrazvukové vlny. Pro takový případ lze intenzitní reflexní koeficient určit jako

$$r_i = \frac{I_r}{I_o} = \frac{\pi \cdot b^2}{4 \cdot \pi \cdot a^2} |r_a|^2 \quad (4)$$



Obrázek 2 Odraz od pevné koule s poloměrem mnohem větším než vlnová délka [6]


kde I_o je intenzita původní vlny a I_r je intenzita odražené vlny, $b[m]$ je poloměr vyzařované vlnoplochy a $a[m]$ je poloměr koule, na kterou vlna dopadá. Pro velmi velké plošné objekty lze intenzitní reflexní koeficient aproximovat jako

$$r_i = |r_a|^2 \quad (5)$$

S rostoucím rozdílem akustických impedancí tkání mezi orgány roste i poměrná intenzita odražené vlny [6], [8].

Pokud vlna nedopadne na hranici mezi druhým objektem kolmo, vlna se láme podle Snellova zákona lomu:

$$\frac{\sin \alpha}{\sin \beta} = \frac{c_1}{c_2} \quad (6)$$




Obrázek 3 Lom ultrazvukové vlny při šikmém dopadu na rozhraní dvou prostředí

kde $\alpha[^\circ]$ je úhel, pod kterým dopadne vlna na rozhraní, $\beta[^\circ]$ je úhel, pod kterým vlna pokračuje, c_1 a $c_2 [m \cdot s^{-1}]$ je rychlost šíření zvuku v prvním resp. druhém prostředí. Část vlny je opět odražena s amplitudovým reflexní koeficientem podle vztahu (7).

$$r_a = \frac{Z_2 \cos \alpha - Z_1 \cos \beta}{Z_1 \cos \beta + Z_2 \cos \alpha} \quad (7)$$

3.1.2.2 Difuzní rozptyl


Pokud vlna narazí na objekt, který má jinou hustotu nebo stlačitelnost, než dosavadní prostředí, a objekt je mnohem menší, než vlnová délka vlny, dochází k difuznímu rozptylu. Pokud je uvažován případ, že hustota objektu je stejná jako dosavadní prostředí, a je pouze jiná stlačitelnost, dochází k monopolní radiaci vlny. Pokud je však stlačitelnost stejná, a je rozdíl v hustotě, dochází k dipólové radiaci (obr. 4). Skutečné objekty vykazují kombinaci těchto zmíněných jevů [6], [8].



Obrázek 4 Vlevo monopolní radiace vlny, vpravo dipólová radiace vlny způsobená difuzním rozptylem

Opět pro sférický objekt (obr.5) je dán vztah

$$r_i = \frac{k^4 a^6}{9b^2} \left[\frac{3(1 - \frac{\rho_2}{\rho_1}) \cos \theta}{1 + 2 \frac{\rho_2}{\rho_1}} + \left(1 - \frac{\kappa_1}{\kappa_2} \right) \right]^2 \quad (8)$$



Obrázek 5 Odraz od pevné koule s poloměrem mnohem menším než vlnová délka [6]

Kde $a[m]$ je poloměr koule, $b[m]$ je poloměr vlnoplochy a k je dáno vztahem (3), $\rho[Pa]$ je hustota objektu, $\kappa[Pa^{-1}]$ je stlačitelnost objektu a $\theta[rad]$ je úhel vyzařování, kde $\theta = 0$ je směr, kterým postupuje vlna. Pokud je uvažována tuhá koule, pro kterou platí $\frac{\rho_2}{\rho_1} \rightarrow \infty$ a $\frac{\kappa_1}{\kappa_2} \rightarrow \infty$, přechází (8) do následujícího tvaru

$$r_i = \frac{k^4 a^6}{9b^2} \left[1 - \frac{3 \cos \theta}{2} \right]^2 \quad (9)$$

V této oblasti velikosti objektu, kdy $k \cdot a \ll 1$, se intenzita mění se čtvrtou mocninou frekvence. Tento rozptyl se často nazývá Rayleighův rozptyl a podílí se na vzniku *speckle* šumu, který bude podrobněji popsán v další části [6], [8].

3.1.2.3 Difrakční rozptyl

Složitější směr rozptylu nastává, pokud je velikost objektu přibližně srovnatelná s velikostí vlnové délky ultrazvukové vlny. V takovém případě mají velký význam vlastnosti tkání, jako je např. elasticita, dále je významný úhel dopadu apod. Analytické řešení pro sférický objekt s elastickými vlastnostmi popsal Faran [7].

3.1.3 Útlum ultrazvukové vlny

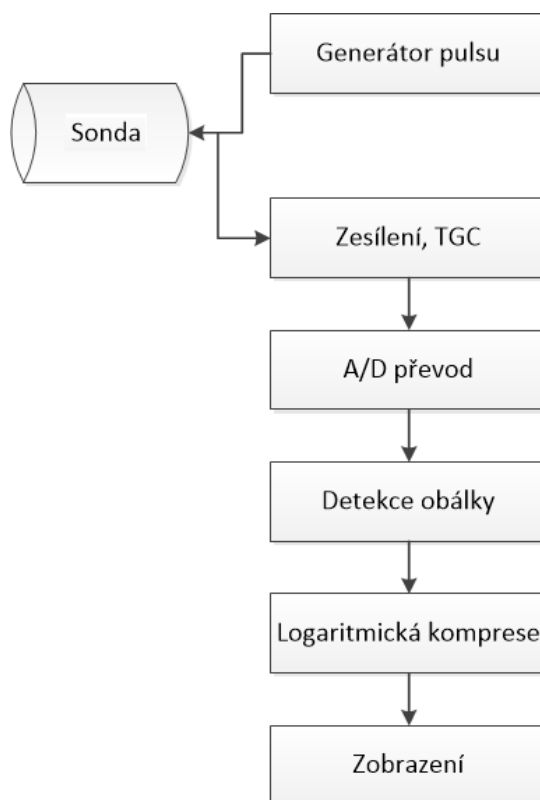
Průchodem ultrazvukové vlny tkáněmi dochází k absorpci části energie vlny, kdy se tato mechanická energie mění v teplo. Pohlcení vlny je různé v závislosti na typu tkáně a frekvenci vlny. Amplituda detekované odražené vlny je dána vztahem

$$A = A_0 \cdot e^{-\alpha \cdot 2d} \quad (10)$$

kde A je amplituda reflektované vlny, A_0 je amplituda vyslané vlny, α [$dB \cdot cm^{-1} \cdot MHz^{-1}$] je absorpční koeficient a $d[m]$ je vzdálenost překážky, od které se vlna odrazila. Se vzrůstající frekvencí vyslané vlny se zvětšuje axiální rozlišovací schopnost, ale roste i hodnota absorpčního koeficientu, čímž klesá hloubka, ve které lze tkáň vyšetřovat. Zeslabení ultrazvukové vlny je způsobeno také difuzním rozptylem, který je rovněž frekvenčně závislý [5].

3.2 Generování a zpracování ultrazvukového signálu


Na obr. 6 je velmi zjednodušené schéma znázorňující generování a část úseku zpracování ultrazvukového signálu.



Obrázek 6 Základní kroky generování a následné zpracování přijatého ultrazvukového signálu

3.2.1 Generování pulsu

Pulz, kterým jsou buzeny piezoelektrické snímače, lze popsat jako sinusový průběh o frekvenci f_c , jehož amplituda je modulována Gaussovou funkcí. Takový pulz je naznačen na obr. 7. Amplitudové spektrum má tedy následně tvar Gaussovy křivky se střední hodnotou na frekvenci f_c . Směrodatná odchylka Gaussovy modulační křivky ovlivňuje šířku pulzu, a s tím spojenou axiální rozlišovací schopnost. Čím kratší je pulz v prostorové oblasti, tím širší je jeho spektrum. Gaussov tvar pulzu je vhodný zejména proto, že při prostupu ultrazvukové vlny prostředím s lineárním součinitelem zeslabení je zachován Gaussov tvar spektra pulzu po přijetí.



Obrázek 7 Vlevo příklad generovaného pulzu v časové oblasti, vpravo spektrum generovaného signálu

3.2.2 Zesílení, TGC

Je provedeno zesílení všech přijatých ech, v případě TGC jsou navíc selektivně zesílena echa z vybraných hloubek.

3.2.3 AD převodník


Před samotným převodem je samozřejmě uvažován anti-aliasingový filtr se zesilovačem pro pokrytí celého dynamického rozsahu ADC.

3.2.4 Detekce obálky

Z přijatého signálu se na vzniku obrazu podílí pouze obálka tohoto signálu. Jednou z možností detekce obálky je použití Hilbertovy transformace. Hilbertova transformace vytvoří komplexní helikální signál, tzv. *analytický signál*. Komplexní složka tohoto signálu je dána původním signálem s posunutou fází o $\frac{\pi}{2}$. Obálka původního signálu $e(t)$ je poté určena jako amplituda *analytického signálu*


$$e(t) = \sqrt{x(t)^2 + \hat{x}(t)^2} \quad (11)$$

kde $x(t)$ je původní signál a $\hat{x}(t)$ je signál získaný Hilbertovou transformací signálu $x(t)$.




Obrázek 8 Syntetický přijatý RF signál

Analytický signál syntetického přijatého radiofrekvenčního signálu



Obrázek 9 Analytický signál vytvořený z RF signálu



Obrázek 10 RF signál s detekovanou obálkou(červeně)

Na obr.8 je příklad syntetického sondou přijatého signálu z jednotné oblasti, ve které se nachází větší množství odražečů (podrobněji bude popsáno v další sekci 3.3). Obr. 9 poté ukazuje *analytický signál* jako komplexní helikálu vytvořenou Hilbertovou transformací a na obr. 10 je získaná obálka z analytického signálu podle vztahu (11).


3.2.5 Logaritmická komprese

Dynamický rozsah přijatého signálu je v rozmezí 50-70dB. Pro zobrazení na běžných monitorech ultrasonografických přístrojů, které mají dynamický rozsah v rozmezí 20-30dB, je nutné tento rozsah redukovat. Nejčastěji je používána právě logaritmická komprese [9].

3.3 Speckle

Speckle šum je forma multiplikativního lokálně nekorelovaného šumu. Tímto, na pohled zrnitým šumem, jsou nejvíce zatíženy právě ultrazvukové snímky. Jak již bylo naznačeno v předchozí části, *speckle* vzniká především v důsledku difuzního rozptylu na nehomogenitách menších, než je vlnová délka ultrazvukové vlny. Je tedy zřejmé, že *speckle* neobsahuje žádnou informaci o anatomii zkoumaného orgánu. Naopak významně znesnadňuje analýzu ultrazvukových snímků, a to jak při vyhodnocování pohledem, tak při počítačové analýze [6], [8].

Speckle šum není zcela náhodný. Při provedení měření tkáně za stejných podmínek, zejména při stejných parametrech měřicího přístroje a náklonu sondy, výsledný *speckle* bude vždy stejný. Pokud je uvažována jednotná oblast s velkým výskytem částic, které způsobují difuzní rozptyl, rozptýlené vlny dorazí k přijímači s malým rozdílným zpožděním. Jak je uvedeno v části (3.2), pro další zpracování je detekována pouze obálka. Pokud je sestaven histogram amplitud této obálky, jak je naznačeno na obr. 11, podléhá tento histogram Rayleighovu rozložení, kde je střední hodnota μ úměrná směrodatné odchylce v poměru $\frac{\mu}{\sigma} = 1,91$ [4], [6], [10].



Obrázek 11 Histogram amplitud RF signálu(modře), odpovídající Rayleighova funkce(červeně)

Dále je uvažován obraz, který by vznikl přímo za sondou, ještě před dalším zpracováním. Tento obraz se nazývá RF obraz. Každý jeho pixel lze popsat jako

$$z_{x,y} = x_{x,y} \cdot u_{x,y} + w_{x,y} \quad (12)$$

kde $z_{x,y}$ je zašuměný pixel, $x_{x,y}$ je pixel bez šumu, $w_{x,y}$ je aditivní šum, $u_{x,y}$ značí multiplikativní šum a x, y jsou souřadnice daného pixelu. Pro aditivní šum platí, že má vlastnosti jako náhodný bílý šum, kde tedy

$$E[w_{x,y}] = 0 \quad (13)$$

a není závislý na $z_{x,y}$. Na ultrazvukových snímcích lze však aditivní šum oproti multiplikativnímu zanedbat a dále uvažovat pouze vztah(14) [11].

$$z_{x,y} \approx x_{x,y} \cdot u_{x,y} \quad (14)$$

Jak bylo zmíněno, předchozí zápis se vztahuje na RF obraz. Další zpracování, zejména logaritmická komprese, ovlivní jak vzhled obrazu, tak statistické vlastnosti *specklu*. Střední hodnota Reyleighovy distribuce již není úměrná směrodatné odchylce, ale stává se úměrná rozptylu. Rozptyl *speckle* šumu v obraze po logaritmické kompresi lze vypočítat tak, že je nejprve obraz rozdělen na několik částí, v nich je spočítán dílčí rozptyl, a nakonec se spočítá průměr těchto rozptylů, což dá výsledný rozptyl *speckle* šumu v obraze [4],

$$\sigma_n^2 = \sum_{k=1}^K \frac{\sigma_k^2}{\bar{n}_k} \quad (15)$$

kde σ_k^2 je rozptyl šumu uvnitř okna, \bar{n}_k je střední hodnota šumu v okně, a K je počet oken. Logaritmickou kompresí je tak ovlivněn Rayleighův tvar hustoty pravděpodobnosti. *Speckle* se potom blíží spíše bílému Gaussovskému šumu [4], [9].

Po aplikaci logaritmické komprese lze přepsat vztah (14) na

$$\log(z_{x,y}) = \log(x_{x,y} \cdot u_{x,y}) \quad (16)$$

a tedy

$$\log(z_{x,y}) = \log(x_{x,y}) + \log(u_{x,y}) \quad (17)$$

kde $\log(z_{x,y})$ je zašuměný pixel po logaritmicke kompresi. Pro čitelnější formu bude dále používán zápis

$$n_{x,y} = f_{x,y} + l_{x,y} \quad (18)$$

pro který platí, že $\log(z_{x,y})$ je $n_{x,y}$, $\log(x_{x,y})$ je $f_{x,y}$ a $\log(u_{x,y})$ je $l_{x,y}$.

3.4 Artefakty

Kromě *speckle* šumu se na ultrazvukových snímcích často vyskytují i další artefakty, které lze částečně potlačit změnou nastavení parametrů ultrasonografu.

Mezi časté artefakty patří *reverberace*, tedy artefakt vzniklý několikanásobnými odrazy od hyperechogenních těles. Na snímku se pak taková plocha zobrazí falešně opakovaně i ve větších hloubkách s nižší intenzitou [12].

Pokud je většina, nebo veškerá energie dopadajících ultrazvukových vln od objektu odražena, vzniká za takovýmto tělesem akustický stín, kdy není možné pozorovat, co je ve větších hloubkách za objektem. Tento artefakt často vzniká za kalcifikovanými aterosklerotickými pláty [12].

Při průchodu ultrazvukového signálu prostředím s malým útlumem, a následným nárazem vlny na objekt s větší akustickou impedancí, jsou odrazy silnější. Jeví se tedy, že má struktura vyšší echogenitu. Tento artefakt se nazývá *falešné zesílení*. Opačným způsobem se projevuje a vzniká artefakt *falešného zeslabení* [12].

Mezi další artefakty patří například *zdvojení obrazu* v důsledku lomu vln na hranici s velkým rozdílem akustických impedancí, nebo *zrcadlový artefakt*, vznikající na velkých, silně echogenních plošných strukturách [12].

4 Zpracování obrazu

4.1 Filtry odstraňující spackle šum

4.1.1 Statistické filtry

Následující filtry byly navrženy původně pro radarové SAR snímky, které obsahují rovněž formu *speckle* šumu. Filtry počítají novou hodnotu pixelu na základě statistických vlastností sousedních pixelů v pohyblivém okně. Tyto filtry jsou adaptivní do té míry, že v oblastech mimo hrany obraz v daném okně průměrují, a v místech, kde se nacházejí hrany objektů, je zachována původní hodnota pixelů. Uvnitř okna je na základě statistických momentů prvního a druhého řádu (existují i filtry, které využívají statistické momenty vyšších řádů [20]) určen váhový koeficient, a podle daného prahu je rozhodnuto, jestli bude filtr inhibován, nebo bude průměrovat [4], [19], [20].

Je zřejmé, že klíčovou roli zde hraje zvolená velikost okna. Tvar, i když to není podmínkou, bývá čtvercový. Pokud bude okno příliš velké, může se stát, že budou rozmazány i hrany. V případě příliš malého okna je naopak snížena vyhlazovací schopnost filtru. Velikost okna se na základě zkušeností volí většinou 7x7. Další negativní vlastností těchto filtrů je, že v okolí hran zůstane šum, jelikož v těchto místech je filtr inhibován [4], [19].

4.1.1.1 Frost filtr

Funkce Frost filtru je založena na konvoluci obrazu s jádrem filtru, které je exponenciálně tlumené.

$$f_{x,y} = \sum_{x,y \in \eta_s} n_{x,y} m_{x,y} \quad (19)$$

kde $f_{x,y}$ je výsledný vyfiltrovaný obraz, $n_{x,y}$ je původní obraz s šumem, η_s je okolí středového bodu jádra a $m_{x,y}$ je jádro fitru.

$$m_{x,y} = \frac{e^{-K\sigma_n^2 d_{((x_0,y_0),(x,y))}}}{\sum_{x,y \in \eta} e^{-K\sigma_n^2 d_{((x_0,y_0),(x,y))}}} \quad (20)$$

Zde, (x_0, y_0) jsou souřadnice aktuálního filtrovaného pixelu uvnitř okna, (x, y) jsou souřadnice sousedních pixelů v okně, d značí Euklidovskou vzdálenost mezi filtrovaným pixelem a sousedními pixely v okně podle vztahu (21),

$$d_{((x_0,y_0),(x,y))} = \sqrt{(x - x_0)^2 + (y - y_0)^2} \quad (21)$$

a K je tlumící koeficient. $K\sigma_n^2$ je nulové v hladkých oblastech, což způsobí, že filtr průměruje. V oblasti hran musí být $K\sigma_n^2$ naopak velké, aby byl filtr inhibován [14].

4.1.1.2 Lee filtr

Lee filtr vychází z modelu speckle šumu popsaného vztahem (18), kdy na základě minimalizaci střední kvadratické chyby (MMSE) odhaduje hodnotu pixelů bez šumu [12].

$$f_{x,y} = \bar{n} + k_{x,y}(n_{x,y} - \bar{n}) \quad (22)$$

zde \bar{n} je střední hodnota v daném okně a $k_{x,y}$ je statisticky určený váhový koeficient,

$$k_{x,y} = \frac{(\bar{n}^2 - \sigma_n^2 \bar{n}^2)}{(n_{x,y} - \bar{n})^2} \quad (23)$$

kde σ_n^2 je rozptyl dle vztahu (15). Koeficient $k_{x,y}$ se blíží nule v hladkých oblastech. Naopak hodnoty jedna dosahuje v místech s hranami. Na stejném principu, tedy na MMSE pracuje i Kuan filtr [15].

Kromě dvou výše zmíněných filtrů založených na statistických momentech uvnitř okna, existuje celá řada filtrů spadající do této kategorie. Jsou to například Gamma filtr [16], *enhanced* Lee filtr [13] nebo *enhanced* Frost filtr [20]. Poslední dva zmíněné filtry jsou založeny na dalším váhovém koeficientu, kdy se již nerozhoduje pouze mezi dvěma stavy, průměrování a inhibicí, ale existuje i třetí stav, zaručující jistý kompromis mezi těmito extrémy. Všechny tyto filtry jsou určeny téměř výhradně pro SAR snímky, kdy využívají pro danou oblast specifické parametry pro určení dalších koeficientů. Pro využití těchto filtrů na ultrazvukové snímky je proto nutné stanovit tyto některé koeficienty alternativními způsoby.

4.1.2 Difuzní filtry

Difuzní filtry jsou založeny na řešení parciální diferenciální rovnice, kdy tedy odpadají problémy spjaté s vhodnou velikostí okna. Je však potřeba zvolit vhodný počet iterací, který ovlivňuje výsledek filtru. Difuzní filtry lze přímo aplikovat na snímky po logaritmické kompresi.

4.1.2.1 Anizotropně difuzní filtr

Difuze je obecně fyzikální proces, který vyrovnává rozdíly v koncentraci, aniž by docházelo k destrukci nebo k vytváření nové látky. Tento proces je popsán Fickovým zákonem:

$$j = -D \cdot \nabla u \quad (24)$$

Jak je vidět z předcházejícího vztahu, koncentrační gradient ∇u vyvolává difuzní tok, kde j je hustota toku, která má snahu vyvážit gradient. Vztah mezi ∇u a j popisuje difuzní tenzor D , tedy pozitivně definitní symetrická matice. Pokud platí lineární závislost mezi hustotou difuzního toku a koncentračním gradientem, jedná se o izotropní difuzi. V takovém případě lze difuzní tenzor nahradit pozitivní skalární hodnotou g , která se nazývá difuzivita. V případě *anizotropní difuze* však nelze uvažovat vztah úměry [21].

Výše zmíněný děj přenosu látky lze popsat obecně rovnicí kontinuity

$$\frac{\partial u}{\partial t} = -\text{div}(j) \quad (25)$$

kde t značí čas. Po dosazení vztahu prvního Fickova zákona z (24) do rovnice (25) se získá rovnice *difuze*, kterou popisuje druhý Fickův zákon.

$$\frac{\partial u}{\partial t} = -\text{div}(D \cdot \nabla u) \quad (26)$$

V případě obrazu ve stupních šedi je koncentrace dána jasovou intenzitou. Izotropní difuze ve zpracování obrazu je totožná s vyhlazením Gaussovským filtrem [18] ,[21], [23].

$$\frac{\partial n_{x,y,t}}{\partial t} = -\text{div}(c \cdot \nabla n_{x,y,t}) = c \cdot \Delta n_{x,y,t} \quad (27)$$

S myšlenkou použít princip anizotropní difuze ve zpracování obrazu poprvé přišli Persona a Malik [18]. V tomto případě je difuzní tenzor D nahrazen lokálně adaptivní difuzní konstantou $c_{x,y,t}$. Difuzní rovnici lze pak přepsat do tvaru (28).

$$\frac{\partial n_{x,y,t}}{\partial t} = -\text{div}(c_{x,y,t} \cdot \nabla n_{x,y,t}) = c_{x,y,t} \cdot \Delta n_{x,y,t} + \nabla c_{x,y,t} \cdot \nabla n_{x,y,t} \quad (28)$$


Difuzní lokálně adaptivní konstanta $c_{x,y,t}$ je závislá na hodnotě lokálního gradientu cd . Funkce cd je monotónně klesající funkce normalizována tak, aby v místě s nulovým gradientem byla rovna jedné. Persona a Malik představili dvě možné varianty funkce cd ,

$$cd(\nabla n_{x,y}) = \frac{1}{1 + \left| \frac{\nabla n_{x,y}}{K} \right|^2} \quad (29)$$


a

$$cd(\nabla n_{x,y}) = e^{\frac{-\nabla n_{x,y}^2}{K^2}} \quad (30)$$

Dosazením (29 nebo 30) do vztahu (28) je zřejmé, že hodnota hustoty toku bude nízká v místech s vysokým gradientem, tedy v oblasti hran, a maxima bude dosaženo v místě s hodnotou modulu gradientu K . Více patrné je to z obr. 12 a 13 [18], [23].



Obrázek 12 Průběh funkce podle vztahu (29) (červeně), rychlost difuze (modře) pro $K=5$



Obrázek 13 Průběh funkce podle vztahu (30) (červeně), rychlost difuze (modře) pro $K=10$

Další alternativu funkce cd představil například Black a Sapiro v [24].

Důležitou vlastností nelineární anizotropní difuze je tedy schopnost filtrovat i v okolí hran. Pokud by byla uvažována nelineární difuze, tedy takový proces, který zastaví difuzi v oblasti hran, budou tyto hrany sice zachovány, ale jejich blízké okolí bude i nadále obsahovat šum. Tato vlastnost anizotropní difuze, tedy schopnost filtrovat paralelně s hranou i v její blízkosti, je více patrná z diskrétní formy jejího popisu [18], [19].

Vztah (28) je diskretizován do následujícího tvaru

$$n_{x,y}^{t+\Delta t} = n_{x,y}^t + \Delta t \left[(c_{x,y})_n (\nabla n_{x,y})_n + (c_{x,y})_s (\nabla n_{x,y})_s + (c_{x,y})_w (\nabla n_{x,y})_w + (c_{x,y})_e (\nabla n_{x,y})_e \right] \quad (31)$$

kde pro dodržení stability musí platit $0 \leq \Delta t \leq \frac{1}{4}$. Laplacián je tedy nahrazen diferencemi s čtyřmi nejbližšími sousedy (N-north, S-south, E-east, W-west) [18],

$$(\nabla n_{x,y})_n = n_{x+1,y} - n_{x,y}$$

$$(\nabla n_{x,y})_s = n_{x,y-1} - n_{x,y}$$

$$(\nabla n_{x,y})_e = n_{x-1,y} - n_{x,y}$$

$$(\nabla n_{x,y})_w = n_{x,y+1} - n_{x,y}$$

z čehož vyplývá, že při výpočtu se uvažují čtyři směrové koeficienty dány

$$(c_{x,y})_n = cd \left((\nabla n_{x,y})_n \right)$$

$$(c_{x,y})_s = cd \left((\nabla n_{x,y})_s \right)$$


$$(c_{x,y})_e = cd((\nabla n_{x,y})_e)$$

$$(c_{x,y})_w = cd((\nabla n_{x,y})_w)$$

Významnou roli při aplikaci filtru hraje hodnota K a počet iterací. Hodnota K je nejčastěji určena staticky. Existuje však několik návrhů, jak K vypočítat z obrazové funkce. Jedním ze způsobů je určit histogram z modulů gradientů v obraze, kdy se K volí jako 90% kvantil histogramu a je přepočítáván při každé iteraci. Výhodou je, že s postupnou filtrací, tedy úbytkem šumu, klesá síla filtru K , díky čemuž rovněž klesá význam zvoleného počtu iterací [23]. Dalším způsobem podle [24] je určit K z mediánů gradientů v obraze, nebo například stanovit K pomocí odhad šumu morfologickými operátory viz. [25].

4.1.2.2 Speckle redukující anizotropně difuzní filtr

SRAD [19] je založen na podobnosti mezi Frost, Lee a anizotropně difuzním filtrem. Pokud je u Lee filtru předpokládané okno ve tvaru obr.14.



Obrázek 14 Tvar masky filtru

, lze vztah (22) upravit následovně,

$$\begin{aligned} f_{x,y} &= n_{x,y} + (1 - k_{x,y})(\bar{n} - n_{x,y}) \\ &= n_{x,y} + (1 - k_{x,y}) \frac{1}{|\bar{\eta}_s|} \nabla^2 n_{x,y} \end{aligned} \quad (32)$$

kde $\bar{\eta}_s = \{(x+1, y), (x-1, y), (x, y+1), (x, y-1)\}$ a potom $|\bar{\eta}_s|$ je počet okolních pixelů, tedy 4. Jelikož platí, že

$$\begin{aligned} \nabla^2 n_{x,y} &= n_{x+1,y} + n_{x-1,y} + n_{x,y+1} + n_{x,y-1} - 4n_{x,y} \\ &= \sum_{p \in \bar{\eta}_s} (n_p - n_{x,y}) \end{aligned} \quad (33)$$

lze vidět, že Lee filtr za těchto okolností představuje diskrétní izotropní difuzi. Pokud se navíc uvažuje koeficient k jako směrově proměnný, lze vztah přepsat do tvaru (34).

$$\begin{aligned} f_{x,y} &= g_{x,y} + \frac{1}{|\bar{\eta}_s|} [(1 - k_{x+1,y})(n_{x+1,y} - n_{x,y}) \\ &\quad + (1 - k_{x-1,y})(n_{x-1,y} - n_{x,y}) \\ &\quad + (1 - k_{x,y+1})(n_{x,y+1} - n_{x,y}) \\ &\quad + (1 - k_{x,y-1})(n_{x,y-1} - n_{x,y})] \end{aligned} \quad (34)$$

Vztah (34) lze zapsat ve zkrácené formě

$$f_{x,y} = n_{x,y} + \frac{1}{|\bar{\eta}_s|} \operatorname{div}[(1 - k_{x,y}) \nabla n_{x,y}] \quad (35)$$

což je tvar anizotropní difuze, kde $\Delta t = 1$.

Obdobným způsobem pro okolí čtyř bodů lze upravit i Frost filtr, aby připomínal vztah difuze

$$f_{x,y} = n_{x,y} + \frac{1}{|\bar{\eta}_s|} \operatorname{div}[m_{x,y} \nabla n_{x,y}] \quad (36)$$

Parciální diferenciální rovnice odvozena z adaptivních statistických filtrů má tvar

$$n_{x,y}^{t+\Delta t} = n_{x,y}^t + \frac{\Delta t}{|\bar{\eta}_s|} \operatorname{div}[cd(C_{x,y}^t) \nabla n_{x,y}^t] \quad (37)$$

kde

$$C_{x,y}^2 = \frac{\frac{1}{2} |\nabla n_{x,y}|^2 - \frac{1}{16} (\nabla^2 n_{x,y})^2}{\left(n_{x,y} + \frac{1}{4} \nabla^2 n_{x,y}\right)^2} - 1 \quad (38)$$

a musí platit $cd(C_{x,y}^t) \geq 0$. Tento váhový koeficient kombinuje velikost gradientu s normalizovaným laplaciánem, kdy v případě relativně vysokého modulu gradientu a nízkého laplaciánu ukazuje na přítomnost hrany. Funkce $c(\cdot)$ je stejně jako v případě obecné anizotropní difuze nezáporná klesající funkce [18].

4.1.3 Mediánový filtr

Mediánový filtr je založen na pohyblivém okně, kdy prostřední bod okna je nahrazen mediánem hodnot v okně.

4.1.4 Mean-shift filtr

Mean shift je metoda, která se nejčastěji používá pro sledování (*tracking*) pohybujícího se objektu na videu, případně k segmentaci. Je založena na interpretaci obrazu jako funkci hustoty pravděpodobnosti, kdy hustota rozložení pixelů, které jsou od sebe hodnotou intenzity vzdáleny maximálně o předem určený limit, tvoří třetí rozměr grafu. Místa s největší hustotou tak vytváří lokální maxima.


V okolí každého bodu, které je definováno jádrem K , je určen vážený průměr vzorků, do kterého je následně přesunut střed jádra. Jádro K je radiální symetrická funkce, určena různými profily. Odhad hustoty pravděpodobnosti v okně je stanoven pomocí neparametrické metody *kernel density estimation* (*Parzen window*). Pro obecný kernel je odhad hustoty v bodě \mathbf{x} určen podle (39) [26],

$$f(\mathbf{x}) = \frac{1}{n} \sum_{i=1}^n K_h(\mathbf{x} - \mathbf{x}_i) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{\mathbf{x} - \mathbf{x}_i}{h}\right) \quad (39)$$

kde n je počet vzorků (pixelů s požadovanou intenzitou), \mathbf{x}_i jsou dané vzorky, h je velikost jádra, a $K(\cdot)$ je jádro. Profil jádra může být různý. Nejčastěji se používá

a) Uniformní jádro


$$K_u(x) = \begin{cases} c, & \|x\| \leq 1 \\ 0, & \text{jinak} \end{cases} \quad (40)$$



Obrázek 15 Řez uniformním jádrem

b) Epanečnikovo jádro


$$K_e(x) = \begin{cases} c(1 - \|x\|^2), & \|x\| \leq 1 \\ 0, & \text{jinak} \end{cases} \quad (41)$$



Obrázek 16 Řez Epanečnikovým jádrem

c) Gaussovo jádro

$$K_g(\mathbf{x}) = c \cdot e^{-\frac{1}{2}\|\mathbf{x}\|^2} \quad (42)$$



Obrázek 17 Řez Gaussovým jádrem

Cílem *Mean shift* je, jak je již patrné z názvu, určit vektor posunutí středu jádra do těžiště vzorků v oblasti jádra. Jedná se tedy o výpočet vzestupného gradientu pro odhad hustoty rozložení. Pro obecné jádro je gradient určen vztahem (43).

$$\nabla f(\mathbf{x}) = \frac{1}{n} \sum_{i=1}^n \nabla K_h(\mathbf{x} - \mathbf{x}_i) = \frac{2c}{nh} \sum_{i=1}^n (\mathbf{x} - \mathbf{x}_i) k' \left(\left\| \frac{\mathbf{x} - \mathbf{x}_i}{h} \right\|^2 \right) \quad (43)$$

Při filtraci je uživatelem zadána hodnota velikosti jádra a velikost, o kterou se může lišit hodnota pixelu, aby byl ještě pixel započítán do odhadované hustoty. Poté je vypočítáno těžiště a průměrná hodnota intenzity. Iterativně je poté jádro přesouváno do takto vypočítaných těžišť. Děje se tak dlouho, dokud je modul gradientu dostatečně velký, nebo do předem určeného počtu iterací. Poté, co jsou posuny jádra zanedbatelné, tedy střed jádra je v místě lokálního maxima odhadnuté hustoty pravděpodobnosti, hodnota výchozího pixelu je nastavena na průměrnou hodnotu jasu pixelů v jádře v místě posledního přesunu.

4.2 Ekvalizace histogramu

Ekvalizace histogramu je postup, který provádí úpravu kontrastu obrazu. Pokud je histogram obrazu úzký, metoda vylepšení kontrastu provede přerozdělení histogramu, kdy hodnoty více zastoupených jasových intenzit jsou vhodně rozšířeny i do okolních hodnot jasů na histogramu. Klasická ekvalizace histogramu se provádí jako úprava průběhu distribuční funkce, která je v obecném případě linearizována. Převodní funkce, podle které je jednotlivým hodnotám jasu z původního obrazu přidělována nová hodnota, je úměrná distribuční funkci obrazu,

$$eq_i = (L - 1) \left(\frac{cdf_i}{M \cdot N} \right) \quad (44)$$

kde i je hodnota intenzity jasu, eq_i je upravená hodnota jasu i po převedení, cdf_i je hodnota distribuční funkce pro danou hodnotu i , M je počet řádků a N je počet sloupců obrazu. Je zřejmé, že sklon distribuční funkce je určen histogramem obrazu.

$$\frac{deq}{di} = \left(\frac{L-1}{M \cdot N} \right) \cdot hist_i \quad (45)$$

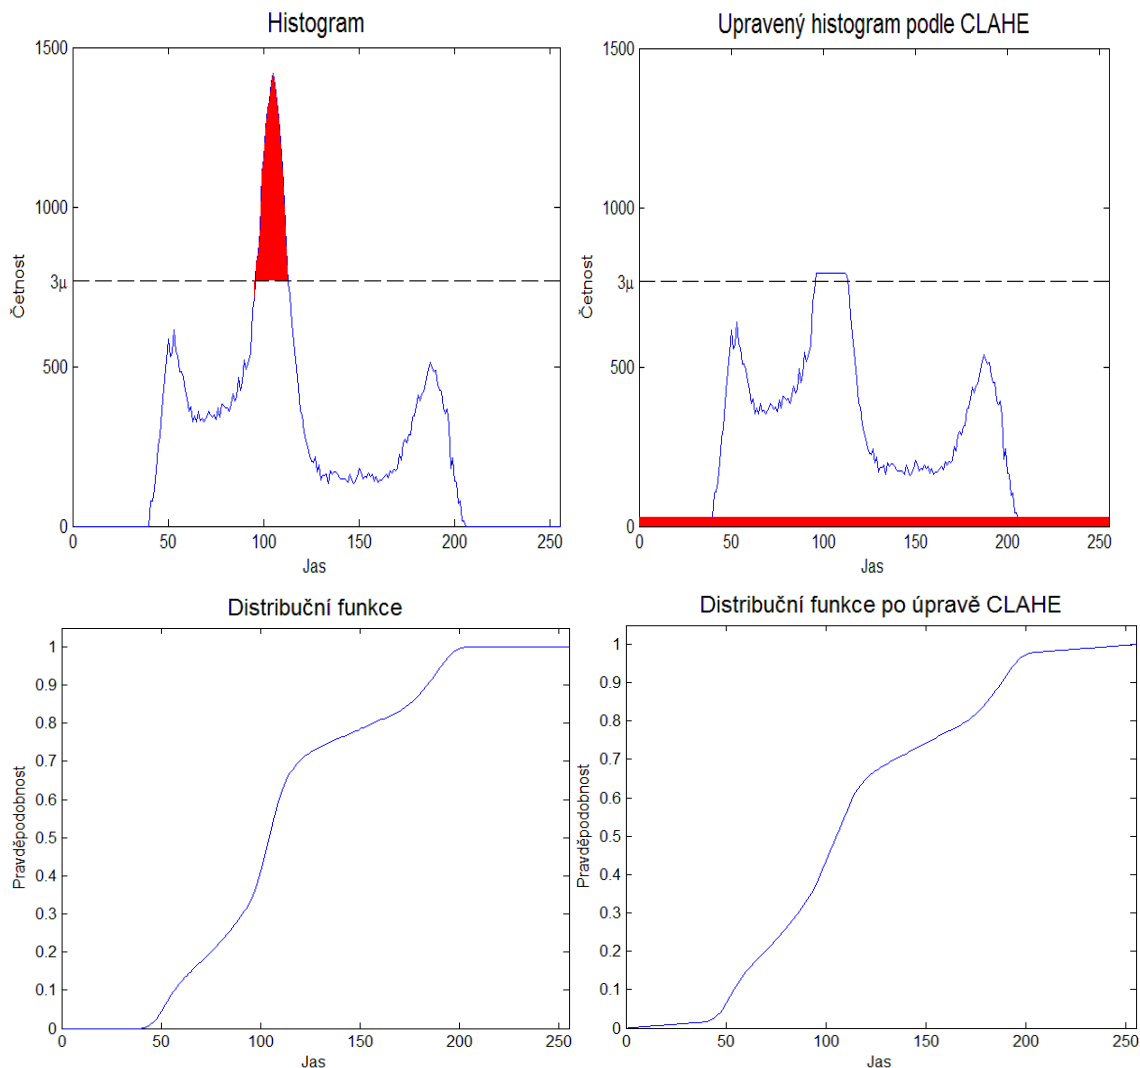
kde $hist_i$ je výška daného sloupce i histogramu [23], [27].

4.2.1 Adaptivní ekvalizace histogramu (AHE)

Adaptivní ekvalizace histogramu se používá v obrazech, kde se nacházejí oblasti, které jsou výrazně tmavší nebo světlejší, než je zbytek obrazu. Rozložení hodnot jasu tedy není v celém obrazu rovnoměrné. Principem AHE je rozdělit obraz na několik, nejčastěji čtvercových, částí, a v nich poté určit převodní funkci z histogramu pro danou čtvercovou oblast. Pixely, které patří do dané části, jsou poté upravovány pomocí převodní funkce určené pro tuto oblast. Nevýhoda této i obecné metody vylepšení kontrastu je, že zvýrazňuje i šum v obraze. Největší problém nastává v homogenních oblastech, kde je histogram úzký a vysoký. Převodní funkcí je pak rozprostřen v celém rozsahu intenzit [28].

4.2.2 Omezení kontrastu (CLAHE)

CLAHE (*contrast limited adaptive histogram enhancing*) [29] je metoda pro ekvalizaci histogramu, která zabraňuje zvýrazňování šumu, které způsobují předchozí zmíněné metody. Obraz je opět rozdělen do několika částí, jak je tomu u AHE, a je v každé oblasti určen histogram. Principem této metody je omezení sklonu převodní funkce, tedy i sklonu distribuční funkce. Omezení sklonu je dosaženo omezením výšky histogramu. Než je určena distribuční funkce, je nejprve omezen histogram zadaným limitem. Limit je nejčastěji stanoven jako násobek průměrné hodnoty histogramu. Intenzita, která byla omezením histogramu odstraněna, je poté rovnoměrně doplněna do všech sloupců histogramu, jak je naznačeno na obr. 18. Z takto upraveného histogramu je určena převodní funkce stejně jako u předchozích metod.




Obrázek 18 Původní histogram(vlevo nahoře), upravený histogram metodou *CLAHE* (vpravo nahoře), původní distribuční funkce(vlevo dole), distribuční funkce metodou *CLAHE* (vpravo dole)

4.3 Houghova transformace

Houghova transformace slouží k nalezení a popisu geometrických primitiv v obraze. Původní Houghova transformace sloužila k extrakci přímek z obrazu. Postupem času byl tento nástroj rozšířen na hledání kružnic, elips, ale také na obecné tvary, které jsou popsány polygonem. Hlavní výhodou Houghovy transformace je schopnost detekce geometrických primitiv i v obraze obsahujícím šum, kdy může část hledaného objektu chybět. Princip Houghovy transformace vychází z popisu hledaných tvarů v jejich parametrickém prostoru (někdy se uvádí jako Houghův prostor). Například přímku lze v kartézském souřadném systému (x, y) zapsat vztahem:

$$y = ax + b \quad (46)$$



Obrázek 19 Vlevo přímka v prostoru (x,y) s naznačenými body (červeně), vpravo body jako přímky v parametrickém prostoru.

kde a je směrnice přímky a b je tzv. úsek na ose y . V tomto případě by parametrický prostor byl pravoúhlý souřadný systém s osami a a b . Přímka v (x,y) je poté v systému (a,b) popsána jedním bodem. Naopak jeden bod v (x,y) je v (a,b) popsán přímkou viz obr. 19 [22] ,[17].

$$a = \frac{y}{x} - \frac{1}{x}b \quad (47)$$


Skupina bodů, která v prostoru (x,y) ležela na přímce, je prezentována v systému (a,b) přímkami, které se střetávají v bodě $[A,B]$, z kterého lze poté zrekonstruovat původní přímku v (x,y) . Je však třeba zmínit, že tento způsob popisu přímky při použití Houghovy přímkové transformace se již nepoužívá a je nahrazen popisem v polárních souřadnicích. Pro názornost principu Houghovy transformace je však zřejmě nejjasnější [17].

4.3.1 Detekce kružnic

Houghova transformace pro detekci kružnic vychází z popisu kružnice v kartézském souřadném systému (x,y)

$$r^2 = (x - x_0)^2 + (y - y_0)^2 \quad (48)$$

kde $[x_0, y_0]$ je pozice středu kružnice a r značí poloměr. Je tedy zřejmé, že oproti parametrickému prostoru přímky, který byl dvojrozměrný (a,b) , nyní se jedná o trojrozměrný prostor (x_0, y_0, r) . Jeden bod v prostoru (x,y) je v parametrickém prostoru (x_0, y_0, r) reprezentován jako kužel. Například bod $[x_k, y_k]$ v (x,y) tak tvoří nekonečné množství kružnic v (x_0, y_0, r) s pevným středem v $[x_{0k}, y_{0k}]$ o různém poloměru dle osy r . Pokud leží body v (x,y) na kružnici, v parametrickém prostoru se tyto body, reprezentované kužely, střetávají v jednom bodě $[x_{0k}, y_{0k}, r_k]$, z kterého se následně zrekonstruuje původní kružnice [17].



Obrázek 20 Kružnice v prostoru (x,y) (čerchované), naznačených několik kružnic v řezu parametrickým prostorem (x_0, y_0, r) pro poloměr roven poloměru čerchované kružnice (plně)


4.3.1.1 Implementace

Při implementaci Houghovy transformace se musí nejprve vytvořit prázdné pole, které znázorňuje parametrický prostor. Toto pole se nazývá *akumulátor*. Jelikož se tato práce zabývá detekcí krční tepny, bude dále popis zaměřen na Houghovu transformaci pro detekci kružnic. Postup při detekci jiných tvarů, jako je přímka nebo elipsa, je však obdobný. V případě této Houghovy transformace se jedná tedy o trojrozměrný akumulátor. Obraz, ve kterém se hledají objekty ve tvaru kružnice, je v běžném případě nejprve předzpracován. Mezi nejčastější operace předzpracování patří vyhlazení obrazu, následná detekce hran, a poté je obraz prahován. Při Houghově transformaci se poté pro každý hranový bod zkonstruuje kužel v akumulátoru. Tomuto procesu se říká *sbírání hlasů* (*accumulating votes*) a provádí se tak, že místa akumulátoru, kterými prochází rekonstruovaný kužel, se inkrementují nejčastěji o hodnotu jedna. Až je *sběr hlasů* proveden podle všech hranových bodů, hledá se místo v *akumulátoru* s nejvyšší hodnotou. Tento bod, případně oblast, určuje nalezenou kružnici. V obraze může být samozřejmě i více takových objektů, které tvoří lokální maxima v akumulátoru. Způsoby, jak hledat maxima v akumulátoru je více (viz. [17]). Nejjednodušším způsobem je najít voxely akumulátoru s maximálními hodnotami. Zde poté hraje výraznou roli rozlišení akumulátoru. Pokud je rozlišení příliš velké, jsou body okolo nalezeného středu příliš rozprostřeny, tudíž nelze hledat pouze bod s maximální hodnotou. Při nízkém rozlišení je naopak určení původních parametrů kružnice méně přesné.

4.3.2 Zobecněná Houghova transformace

Jak již bylo zmíněno na začátku kapitoly, pomocí Houghovy transformace lze hledat i neanalytické tvary, které jsou určeny pomocí polygonu. Polygon je rozdělen na přímkové segmenty. V krajním případě každý bod tvoří jeden segment. Dále je určen referenční bod kdekoli uvnitř polygonu a z něj jsou vedeny vektory ke středům jednotlivých segmentů. Při implementaci je vytvořena tzv. *R-tabulka*, do které se ukládají informace o těchto vektorech, konkrétně jejich délka a úhel, který svírá vektor se segmentem. Z každého hranového bodu v obraze jsou poté vedeny zaznamenané vektory z *R-tabulky* a na jejich konci je inkrementován akumulátor. Nalezením maxima akumulátoru se určí pozice referenčního bodu polygonu

v obraze. Zobecněná Houghova transformace je dále rozšiřitelná i o hodnoty měřítka nebo rotace polygonu viz např. [17] [22], [17].



Obrázek 21 Vlevo polygon s vektory, které se ukládají do R tabulky, vpravo ukázka přemístění vektorů na hrany, na koncích vektorů je inkrementován akumulátor

4.4 Parametrické aktivní kontury

Dvojměrné parametrické aktivní kontury, neboli deformovatelné objekty, slouží především k interaktivní segmentaci. Jedná se o uzavřené křivky, které lze vnímat jako matematický model pomyslného gumového kruhu. Tento kruh je popsán jednak vnitřními silami, které jej udržují, bez působení dalších sil, v hladkém kruhovém tvaru. Dále hrají významnou roli vnější síly, které jsou odvozeny z funkce obrazu a deformují jej do tvaru objektů na snímku [17], [23].

Jednou z nejvýznamnějších vlastností je výše zmíněná uzavřenost křivky, díky níž lze vytvořit obrys objektu, i když po prahování chybí některé úseky hran.

4.4.1 Vnitřní síly

Nejprve je uvažován takový stav, kdy na kruh nepůsobí žádná vnější síla. Jak již bylo zmíněno, takový kruh má pak prstencový tvar o určitém poloměru, což je dáno rovnováhou vnitřních sil. Pokud je kruh stlačen nebo natažen, a poté opět uvolněn, vrátí se do původního, prstencového tvaru.

Jak uvádí [23], lze si kruh představit jako v sérii spojené, nekonečně malé pružinové elementy. Obvod potom může být označen jako $s(p) = [x(p), y(p)]_{\forall x, y \in \mathbb{R}}$, kde $p = 0$ značí počátek a $p = 1$ konec obvodu, a to bez ohledu na jeho délku. p jsou zmiňované pružinové elementy. Každý takový element je schopen samostatného pohybu. V rovnovážném stavu jsou elementy vzdáleny rovnoměrně od sebe a žádný z nich se nepohybuje. Až při působení vnějších sil se v kruhu indukuje energie [17] [30].

Pokud je kruh roztahován, změní se délka jeho obvodu podle Hookova zákona, kdy je sledována vzdálenost mezi jednotlivými elementy. Délka obvodu kruhu, která je dána první derivací obvodu podle všech elementů, je zároveň úměrná deformační síle, která působí na jednotlivé elementy. Energie potřebná k roztahování kruhu je poté dána:

$$E_{roztahovací} = \int_0^1 \alpha(p) \left| \frac{\partial \mathbf{s}(p)}{\partial p} \right|^2 dp \quad (49)$$

kde α je v tomto případě závislá na pružinovém elementu a určuje pevnost působící proti roztahnutí. Pokud by byla uvažována pouze výše zmíněná energie a snaha o zachování minimálního energetického stavu, minimalizovala by se vzdálenost mezi jednotlivými elementy. Vzhledem k uzavřenému tvaru křivky by se tak kruh stáhl do jednoho bodu [17], [30].

Pružinové elementy lze také stlačovat a kruh ohýbat. Proti stlačení působí síla, určující tuhost pružiny. Ta je dána druhou derivací obvodu křivky přes elementy, což určuje křivost křivky. Ohybová energie je pak dána:

$$E_{ohýbací} = \int_0^1 \beta(p) \left| \frac{\partial^2 \mathbf{s}(p)}{\partial p^2} \right|^2 dp \quad (50)$$

Zde β značí tuhost proti stlačení jednotlivých pružinových elementů. Opět, pokud by byla uvažována pouze ohybová energie, minimalizovala by se křivost. Kromě dosahované hladkosti by křivka konvergovala do tvaru přímky, tedy nekonečného poloměru, kdy je křivost nulová [17], [30].

Výše zmíněné energie se uvažují jako vnitřní

$$E_{vnitřní} = E_{roztahovací} + E_{ohýbací} \quad (51)$$

Gumový kruh má jako fyzikální soustava tendenci minimalizovat svoji vnitřní energii. Výše zmíněné energie tedy působí vůči sobě. Pokud má kruh tvar hladkého prstence, při smršťování se zmenšuje poloměr a roste křivost, naopak minimalizací křivosti se zvyšuje délka obvodu a tím i roztahná energie. Klidový stav je potom takový, kdy součet podle (51) je minimální. Poloměr v klidovém stavu je dán právě koeficienty α a β [17], [30].


4.4.2 Vnější síly

Vnější síly jsou odvozeny z obrazové funkce. Jejich cílem je deformovat konturu do tvarů objektů na snímku. Opět se tak děje za cílem minimalizovat energii, kdy celková energie je dána vztahem (52):

$$E = E_{vnější} + E_{vnitřní} = E_{vnější} + \int_0^1 \left(\alpha(p) \left| \frac{\partial \mathbf{s}(p)}{\partial p} \right|^2 + \beta(p) \left| \frac{\partial^2 \mathbf{s}(p)}{\partial p^2} \right|^2 \right) dp \quad (52)$$

Pro určení vnějších sil se předpokládá, že objekty na snímku jsou charakterizovány svými hranami. Nejsnadněji lze pak sílu v každém místě obrazu určit tak, že je nejprve obraz vyhlazen Gaussovým filtrem, a následně se počítá záporný gradient viz, vztah (53). Pokud je uvažována vnější energie jako energie potenciální, pomyslný kotouč se zjednodušeně řečeno v čase přesunuje podle směru záporného gradientu, tedy do míst s nižší potenciální energií, viz. obr.22. Jestli se kontura skutečně deformuje pod vlivem gradientu, je dáno modulem gradientu, ale také tuhostí a mechanickým napětím kruhu.

$$E_{vnější} = -G_{x,y} * \nabla n_{x,y} \quad (53)$$



Obrázek 22 Nahoře ostrá původní hrana, uprostřed po aplikaci Gaussova filtru, dole záporný gradient vyhlazené hrany

Je však zřejmé, že v oblastech vzdálenějších od hran objektu v obraze, nepůsobí na konturu tyto síly a tudíž nemohou kruh deformovat. Tuto nevýhodu, danou z podstaty výše zmíněného způsobu určení vnější energie, efektivně řeší metoda *gradientního vektorového toku* viz. 4.5.

Bez ohledu na použitou vnější energii je hlavním cílem sestavit vhodnou evoluční rovnici, která vede konturu v čase do stavu minimální energie, a následně vztahy diskretizovat.

Minimalizace vztahu (52) pomocí variačního počtu vede na Euler-Lagrangeovu rovnici popisující extrémy funkcionálu (podrobněji [31]):

$$\frac{\partial E}{\partial \mathbf{s}} - \frac{d}{dp} \left(\frac{\partial E}{\partial \mathbf{s}'} \right) + \frac{d^2}{dp^2} \left(\frac{\partial E}{\partial \mathbf{s}''} \right) = 0 \quad (54)$$

Dosažením vztahu (52) do (54) a výpočtem je získán vztah modelující pohyb kontury v čase

$$\frac{\partial \mathbf{s}}{\partial t} - \alpha(p) \frac{\partial^2 \mathbf{s}(p)}{\partial p^2} + \beta(p) \frac{\partial^4 \mathbf{s}(p)}{\partial p^4} + \frac{\partial E_{vnější}}{\partial p} = 0 \quad (55)$$

Minima je dosaženo, pokud se kontura již dále nepohybuje:

$$-\alpha(p) \frac{\partial^2 \mathbf{s}(p)}{\partial p^2} + \beta(p) \frac{\partial^4 \mathbf{s}(p)}{\partial p^4} + \frac{\partial E_{vnější}}{\partial p} = 0 \quad (56)$$

Při řešení parametrických aktivních kontur přes minimalizace energií má podle [17] značnou nevýhodu v citlivosti na šum, která je způsobena čtvrtou derivací u členu určujícího tuhost. Často se proto volí koeficient β roven nule. Zejména při použití *gradientního vektorového toku* však tento předpoklad výrazně nezhoršuje vlastnosti kontury.

4.4.3 Implementace

Pro implementaci algoritmu je nutné vztah (56) nejprve diskretizovat metodami konečných diferencí.

$$\frac{s_i^{t+1} - s_i^t}{\delta t} = \alpha \frac{s_{i+1}^{t+1} + s_{i-1}^{t+1} - 2s_i^{t+1}}{\delta p^2} - \beta \frac{s_{i+2}^{t+1} - 4s_{i+1}^{t+1} + 6s_i^{t+1} - 4s_{i-1}^{t+1} + s_{i-2}^{t+1}}{\delta p^4} - F_i \quad (57)$$

$$F_i = \nabla E_{ext} \quad (58)$$

kde se bude dále předpokládat zjednodušení, že koeficienty α a β jsou konstantní pro všechny vrcholy polygonu tvořící model. Po roznásobení a substituci je vztah ve tvaru:

$$\begin{aligned} bs_{i+2}^{t+1} - (a + 4b)s_{i+1}^{t+1} + (1 + 2a + 6b)s_i^{t+1} - (a + 4b)s_{i-1}^{t+1} + bs_{i-2}^{t+1} \\ = s_i^t + \delta t F_i \end{aligned} \quad (59)$$

$$\text{kde } a = \alpha \frac{\delta t}{\delta p^2}, b = \beta \frac{\delta t}{\delta p^4}$$

Následně se upraví pravá strana rovnice a je provedena další substituce

$$ps_{i+2}^{t+1} + qs_{i+1}^{t+1} + rs_i^{t+1} - qs_{i-1}^{t+1} + ps_{i-2}^{t+1} = \tilde{s}_i^{t+1} \quad (60)$$

$$\text{kde } \tilde{s}_i^{t+1} = s_i^t + \delta t F_i, p = b, q = -a - 4b, r = 1 + 2a + 6b.$$

Je tak získána série lineárních rovnic. Pro následné řešení jsou tyto zapsány do tvaru pentadiagonální matice \mathbf{M} [31].

$$\mathbf{M} = \begin{bmatrix} r & q & p & & & p & q \\ q & r & q & p & & & p \\ p & q & r & q & p & & \\ & \ddots & \ddots & \ddots & \ddots & \ddots & \\ & & p & q & r & q & p \\ p & & & p & q & r & q \\ q & p & & & p & q & r \end{bmatrix} \quad (61)$$

Pokud jsou tedy koeficienty α a β konstantní, lze matici (konkrétně inverzní matici \mathbf{M}^{-1}) určit ještě před iteračním výpočtem nové pozice každého vrcholu polygonu [31].

$$\mathbf{M}\mathbf{s}^{t+1} = \tilde{\mathbf{s}}^{t+1} \quad (62)$$

$$\mathbf{s}^{t+1} = \mathbf{M}^{-1}(\mathbf{s}^t + \delta t \mathbf{F}_i) \quad (63)$$

Jak bylo zmíněno výše, každý pomyslný pružinový element modelu, který je v diskretním prostoru tvořen vrcholem polygonu popisujícím konturu, je v kartézském souřadném systému popsán složkou x a y . Rovnici (63) lze tak rozdělit na dva samostatné vztahy:

$$\mathbf{x}^{t+1} = \mathbf{M}^{-1}(\mathbf{x}^t + \delta t \mathbf{F}_x) \quad (64)$$

$$\mathbf{y}^{t+1} = \mathbf{M}^{-1}(\mathbf{y}^t + \delta t \mathbf{F}_y) \quad (65)$$

Dosud nezmíněný člen δt je pak logicky délka časového kroku, kterou lze zvolit interaktivně. Čím menší je tento člen, tím je zaručena větší stabilita modelu, ovšem za cenu pomalejšího postupu kontury [31].

4.4.3.1 Shrnutí algoritmu

Celý algoritmus parametrické aktivní kontury sestává z následujících kroků

1. Inicializace počáteční křivky.
2. Výpočet pole vnější síly.
3. Výpočet matice \mathbf{M}^{-1}
4. Určení nové pozice křivky \mathbf{x}^{t+1} a \mathbf{y}^{t+1} podle (64,65)
5. Případné doplnění nebo ubrání vrcholů polygonu
6. Opakovat bod 4-6, dokud neproběhl požadovaný počet iterací.


4.5 Gradientní vektorový tok

Zmíněná vnější energie ze vztahu (53), která působí na konturu tak, že ji přitahuje ke hranám objektů, má několik nevýhod. Prvním je relativně malý dosah tohoto pole, což může způsobovat problémy, pokud je původní kontura umístěna dále od hran objektů, a tedy mimo dosah této síly. V praxi se používá, jak je uvedeno v předchozí části, rozmazání. To však způsobuje zmenšení strmosti hran a tedy i nižší výsledný modul gradientu. Další nevýhodou je, že kontura není přitahována do konkávních oblastí. To může způsobovat, zejména v případě přítomnosti plátu v karotické tepně, kdy vznikají oblasti s velkou křivostí, nepřesnou segmentací.

V roce 1997 Xu a Price [32] přišli s návrhem nové vnější síly, tzv. *gradientním vektorovým tokem* (dále GVF), která je vypočítána z hranového obrazu. Pro určení tohoto pole se vychází z energetické minimalizace následujícího funkcionálu:

$$E_{gvf} = \iint \mu \left[\left(\frac{\partial u}{\partial x} \right)^2 + \left(\frac{\partial u}{\partial y} \right)^2 + \left(\frac{\partial v}{\partial x} \right)^2 + \left(\frac{\partial v}{\partial y} \right)^2 \right] + |\nabla f|^2 |\mathbf{v} - \nabla f|^2 dx dy \quad (66)$$

, kde $\mathbf{v}(x, y) = (u(x, y), v(x, y))$ je GVF, f je hranový obraz, μ je váhový koeficient prvního členu v integrálu a $|\nabla f|$ je váhovým koeficientem druhého členu ve funkcionálu. Ze vztahu (66) je zřejmé, že první člen bude dominantní v oblastech s nulovou hodnotou gradientu f , tedy tam, kde nejsou v obraze hrany a v těchto místech dochází k vyhlazení, tedy difuzi z oblastí s vyšším gradientem. Naopak v blízkosti hran, tedy kdy je ∇f vysoký, bude převládat vliv druhého členu, který minimalizuje rozdíl mezi \mathbf{v} a ∇f . Potom tedy vektory v blízkosti hran, které mají vysoký modul a směřují směrem k hranám, mají tendenci zůstat ve výsledném vektorovém poli nezměněny [32].



Obrázek 23 Vlevo pole vnější síly vytvořené "klasickou" metodou, vpravo GVF

Pravě díky vyhlazení, tedy difuzi, se dostanou vektory, které směřují k hranám, do všech míst obrazu a kontura se tak, nezávisle na původní velikosti, může roztáhnout i ke vzdáleným hranám. Pomocí tohoto principu však pole vtahuje konturu také do konkávních oblastí. Minimalizace funkcionálu (66) pomocí variačního počtu vede na následující Euler-Lagrangeovy rovnice určující minimální stav:

$$\mu \nabla^2 u - \left(u - \frac{\partial f}{\partial x} \right) \left(\left(\frac{\partial f}{\partial x} \right)^2 + \left(\frac{\partial f}{\partial y} \right)^2 \right) = 0 \quad (67)$$

$$\mu \nabla^2 v - \left(v - \frac{\partial f}{\partial x} \right) \left(\left(\frac{\partial f}{\partial x} \right)^2 + \left(\frac{\partial f}{\partial y} \right)^2 \right) = 0 \quad (68)$$

Určení minimálního stavu lze řešit iteračně, pokud u a v zapíšeme jako funkce času, tedy:

$$\frac{\partial u}{\partial t} = \mu \nabla^2 u - \left(u - \frac{\partial f}{\partial x} \right) \left(\left(\frac{\partial f}{\partial x} \right)^2 + \left(\frac{\partial f}{\partial y} \right)^2 \right) \quad (69)$$

$$\frac{\partial v}{\partial t} = \mu \nabla^2 v - \left(v - \frac{\partial f}{\partial x} \right) \left(\left(\frac{\partial f}{\partial x} \right)^2 + \left(\frac{\partial f}{\partial y} \right)^2 \right) \quad (70)$$

Zde si lze všimnout, že se jedná o tzv. zobecněnou rovnici difuze. Pokud bude v určitém místě gradient, a tedy i celý druhý člen, nulový, přejde rovnice do tvaru izotropní difuze [33], [34].

4.5.1 Implementace

Nyní následuje diskretizace a s tím spojené nahrazení derivací konečnými diferencemi:

Rovnice (69) a (70) budou pro lepší přehlednost přepsány jako funkce času a pozice

$$\frac{\partial u_{x,y,t}}{\partial t} = \mu \nabla^2 u_{x,y,t} - \left(u_{x,y,t} - \frac{\partial f_{x,y}}{\partial x} \right) \left(\left(\frac{\partial f_{x,y}}{\partial x} \right)^2 + \left(\frac{\partial f_{x,y}}{\partial y} \right)^2 \right) \quad (71)$$

$$\frac{\partial v_{x,y,t}}{\partial t} = \mu \nabla^2 v_{x,y,t} - \left(v_{x,y,t} - \frac{\partial f_{x,y}}{\partial y} \right) \left(\left(\frac{\partial f_{x,y}}{\partial x} \right)^2 + \left(\frac{\partial f_{x,y}}{\partial y} \right)^2 \right) \quad (72)$$

a dále upraveny do vztahu

$$\frac{\partial u_{x,y,t}}{\partial t} = \mu \nabla^2 u_{x,y,t} - b_{x,y} \cdot u_{x,y,t} + c_{x,y}^1 \quad (73)$$

$$\frac{\partial v_{x,y,t}}{\partial t} = \mu \nabla^2 v_{x,y,t} - b_{x,y} \cdot v_{x,y,t} + c_{x,y}^2 \quad (74)$$

kde

$$b_{x,y} = \left(\frac{\partial f_{x,y}}{\partial x} \right)^2 + \left(\frac{\partial f_{x,y}}{\partial y} \right)^2$$

$$c_{x,y}^1 = b_{x,y} \cdot \left(\frac{\partial f_{x,y}}{\partial x} \right)$$

$$c_{x,y}^2 = b_{x,y} \cdot \left(\frac{\partial f_{x,y}}{\partial y} \right)$$

Po aproximaci derivací konečnými diferencemi jsou získány následující vztahy:

$$u_{x,y}^{t+1} = (1 - b_{x,y} \delta t) u_{x,y}^t + r(u_{x+1,y}^t + u_{x,y+1}^t + u_{x-1,y}^t + u_{x,y-1}^t - 4u_{x,y}^t) + c_{x,y}^1 \delta t \quad (75)$$

$$v_{x,y}^{t+1} = (1 - b_{x,y} \delta t) v_{x,y}^t + r(v_{x+1,y}^t + v_{x,y+1}^t + v_{x-1,y}^t + v_{x,y-1}^t - 4v_{x,y}^t) + c_{x,y}^2 \delta t \quad (76)$$

zde

$$r = \frac{\mu \delta t}{\delta x \delta y} \quad (77)$$

Podle [34] musí být pro zajištění konvergence splněn vztah:

$$\delta t < \frac{\delta x \delta y}{4\mu} \quad (78)$$

kde δt je časový krok.


Rovnice (75,76) lze tedy řešit nezávisle na sobě. Výhodou GVF je také to, že iterační výpočet tohoto pole lze provést předem, a tedy se již nemusí dopočítávat ve smyčce vývoje deformovatelného objektu [23], [33], [34].

4.6 Geometrické aktivní kontury - Chan Vese

Aktivní kontura Chan vese se řadí mezi geometrické aktivní kontury, tedy takové, které jsou popsány implicitně ve formě level setů. Jako i parametrické aktivní kontury, slouží především k segmentaci. Kontura Chan Vese není závislá na hranách, jak je tomu u běžných parametrických nebo jiných geometrických kontur, ale vychází z Mumford-Shahova funkcionálu pro segmentaci. Mumford-Shahův funkcionál je řešen opět pomocí variačního počtu, a právě díky level setové interpretaci je výpočet vývoje křivky částečně ulehčen.

4.6.1 Level set

Jelikož se práce zabývá zpracováním obrazů v dvojrozměrném prostoru, budou i následující odvození uvažována pro \mathbb{R}^2 , ačkoliv level setový popis lze snadno rozšířit na libovolný počet dimenzí. Level setová funkce má tvar $\phi_{x,t}$, kde $\mathbf{x} = (x, y)$ jsou souřadnice bodů a t je čas. V daném čase t křivka $\phi_{x,t}$ rozděluje prostor na dvě části [36].



Obrázek 24 Vývoje kontury popsané level sety.

Pro jednoduchost je uvažována level setová funkce jako jednotková kružnice K v \mathbb{R}^2 se středem v bodě $(0,0)$. Taková kružnice rozděluje prostor na vnitřní a vnější oblast.

$$\text{int } K = \Omega^- = \{\mathbf{x} | |\mathbf{x}| < 1\} \quad (79)$$

$$\text{ext } K = \Omega^+ = \{\mathbf{x} | |\mathbf{x}| > 1\} \quad (80)$$

s hranicí

$$\partial\Omega = \{\mathbf{x} | |\mathbf{x}| = 1\} \quad (81)$$

Implicitní zápis takové funkce je následující

$$\phi_{x,y} = x^2 + y^2 - 1 \quad (82)$$

Kružnice, tedy hranice, která odděluje vnější a vnitřní oblast je definována jako


$$\phi_{x,y} = 0 \quad (83)$$

, vnější oblast Ω^+ :

$$\phi_{x,y} > 0 \quad (84)$$

a vnitřní oblast Ω^-

$$\phi_{x,y} < 0 \quad (85)$$



Obrázek 25 Implicitní reprezentace kružnice s poloměrem 1 a středem v počátku

Zápis aktivní kontury je tedy obecně

$$\Gamma_t = \{\mathbf{x} | \phi_{x,t} = 0\} \quad (86)$$

Pro každý bod $\mathbf{x} = (x, y)$ ve vnější i vnitřní oblasti je spočítána pomocí distanční funkce d_x vzdálenost od nejbližšího bodu $\mathbf{x}_c = (x, y)_c$ ležícího na hranici $\partial\Omega$.

$$d_x = \min_{\mathbf{x}_c \in \partial\Omega} (|\mathbf{x} - \mathbf{x}_c|) \quad (87)$$

potom hodnota každého bodu \mathbf{x} je dána znaménkovou vzdálenostní funkcí

$$\phi_x = \begin{cases} -d_x, & \mathbf{x} \in \Omega^- \\ 0, & \mathbf{x} \in \partial\Omega \\ +d_x, & \mathbf{x} \in \Omega^+ \end{cases} \quad (88)$$

Body ležící ve vnitřním subprostoru tedy mají zápornou hodnotu vzdálenosti, kdežto body ve vnějším podprostoru kladnou [36].

4.6.2 Chan Vese

Jak již bylo zmíněno v úvodu této kapitoly, model Chan-Vese vychází ze specializovaného Mumford-Shahova funkcionálu. Ten slouží k segmentaci popředí od pozadí na základě minimalizace následujícího funkcionálu

$$\begin{aligned} E(c_1, c_2, \Gamma) = & \alpha \int_{\Omega^+} (n_{x,y} - c_1)^2 dx dy + \beta \int_{\Omega^-} (n_{x,y} - c_2)^2 dx dy \\ & + \gamma \int_p |\Gamma_p| dp \end{aligned} \quad (89)$$

Zde první a druhý člen popisuje odchylku intenzity bodů $n_{x,y}$ ve vnitřním podprostoru Ω^+ respektive vnějším podprostoru Ω^- , od průměrné hodnoty intenzity v těchto prostorech c_1, c_2 . Poslední člen zajišťuje hladkost hranice Γ , kde p jsou body patřící hranici. α, β a γ jsou klasicky váhovými koeficienty.

Pro minimalizaci je důležitým krokem vhodně definovat oddělení popředí od pozadí. K tomu je vhodná právě level setová interpretace oblastí. *Level setový* tvar (89) představili Chan-Vese [35] pod názvem *Aktivní kontura bez hran*, což vystihuje vlastnost tohoto modelu, kdy je segmentace založena na regionálních attributech, nikoli na hranách objektů v obraze [23].

Pro definici Ω^+ a Ω^- , tedy oddělení popředí a pozadí, je v *level setové* interpretaci prostoru využita Heavisidova funkce

$$H(\phi_{x,y}) = \begin{cases} 1, & \phi_{x,y} \geq 0 \\ 0, & \phi_{x,y} < 0 \end{cases} \quad (90)$$

Poté lze (89) přepsat do následujícího tvaru [35]

$$\begin{aligned} F(c_1, c_2, \phi) = & \mu \int_{\Omega} |\nabla H(\phi_{x,y})| dx dy + v \int_{\Omega} H(1 - \phi_{x,y}) dx dy \\ & + \lambda_1 \int_{\Omega} |n_{x,y} - c_1|^2 (1 - H(\phi_{x,y})) dx dy \\ & + \lambda_2 \int_{\Omega} |n_{x,y} - c_2|^2 H(\phi_{x,y}) dx dy \end{aligned} \quad (91)$$

Zde c_1 a c_2 jsou průměrné hodnoty popředí, respektive pozadí:

$$c_1 = \frac{\int_{\Omega} n_{x,y} \cdot (1 - H(\phi_{x,y})) dx dy}{\int_{\Omega} (1 - H(\phi_{x,y})) dx dy} \quad (92)$$

$$c_2 = \frac{\int_{\Omega} n_{x,y} \cdot H(\phi_{x,y}) dx dy}{\int_{\Omega} H(\phi_{x,y}) dx dy} \quad (93)$$

λ_1 , λ_2 , μ a v jsou váhové členy. První člen (91) určuje tedy stejně jako v (89) délku hranice, tedy kontury, kdy se při minimalizaci dosahuje větší hladkosti funkce. Druhý člen zaručuje minimalizaci oblasti uvnitř kontury, tedy popředí. Poslední dva členy jsou obdobné prvním dvou členům v (89).

4.6.3 Implementace

Minimalizace funkcionálu $F(c_1, c_2, \phi)$ probíhá opět pomocí Euler-Lagrangeových rovnic a metodou největšího spádu [35], [37]. Je tak získána rovnice popisující pohyb křivky v čase za účelem dosažení stavu energetického minima

$$\begin{aligned} \frac{\partial \phi}{\partial t} = & \delta(\phi) \left(\mu \cdot \left(\int_{\Omega} \delta(\phi) |\nabla \phi| dx dy \right) \cdot \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) - v - \lambda_1 (n - c_1)^2 \right. \\ & \left. + \lambda_2 (n - c_2)^2 \right) \end{aligned} \quad (94)$$

zde $\delta(\phi)$ je Diracův impuls, který vychází z derivace Heavisidovy funkce. Pro implementaci jsou tyto funkce aproximovány například podle následujícího předpisu

$$H_\varepsilon(z) = \begin{cases} 1, & z > \varepsilon \\ 0, & z < \varepsilon \\ \frac{1}{2} \left[1 + \frac{z}{\varepsilon} + \frac{1}{\pi} \sin\left(\frac{\pi z}{\varepsilon}\right) \right], & |z| \leq \varepsilon \end{cases} \quad (95)$$

a tedy

$$\delta_\varepsilon(z) = \begin{cases} 0, & |z| > \varepsilon \\ \frac{1}{2\varepsilon} \left[1 + \cos\left(\frac{\pi z}{\varepsilon}\right) \right], & |z| \leq \varepsilon \end{cases} \quad (96)$$

pro $\varepsilon = 10^{-5}$.

Dále vztah obsahuje známý předpis pro křivost

$$\kappa(\phi) = \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) = \frac{\phi_{xx}\phi_y^2 - 2\phi_{xy}\phi_x\phi_y + \phi_{yy}\phi_x^2}{(\phi_x^2 + \phi_y^2)^{\frac{3}{2}}} \quad (97)$$

kde dolní indexy u funkce ϕ značí výjimečně derivaci, $\phi_x = \frac{\partial \phi}{\partial x}$, $\phi_y = \frac{\partial \phi}{\partial y}$ apod.

Následuje diskretizace metodou konečných diferencí obdobně jako u parametrických kontur (proces diskretizace je podrobně uveden např. v [35]). Výsledný vztah je

$$\phi_{x,y}^{t+1} = F_1 \phi_{x+1,y}^{t+1} + F_2 \phi_{x-1,y}^{t+1} + F_3 \phi_{x,y+1}^{t+1} + F_4 \phi_{x,y-1}^{t+1} + F p_{x,y} \quad (98)$$

kde

$$F = \frac{h}{h + \delta t \delta_\varepsilon(\phi_{x,y}^t) \mu(L(\phi^n))(C_1 + C_2 + C_3 + C_4)} \quad (99)$$

kde

$$L(\phi^n) = \int_{\Omega} \delta(\phi^n) |\nabla \phi^n| dx dy \quad (100)$$

$$C_1 = \frac{1}{\sqrt{(\phi_{x+1,y}^t - \phi_{x,y}^t)^2 + \frac{(\phi_{x,y+1}^t - \phi_{x,y-1}^t)^2}{4}}}, \quad (101)$$

$$C_2 = \frac{1}{\sqrt{(\phi_{x,y}^t - \phi_{x-1,y}^t)^2 + \frac{(\phi_{x-1,y}^t - \phi_{x-1,y-1}^t)^2}{4}}}, \quad (102)$$

$$C_3 = \frac{1}{\sqrt{\frac{(\phi_{x+1,y}^t - \phi_{x-1,y}^t)^2}{4} + (\phi_{x,y+1}^t - \phi_{x,y}^t)^2}}, \quad (103)$$

$$C_4 = \frac{1}{\sqrt{\frac{(\phi_{x+1,y-1}^t - \phi_{x-1,y-1}^t)^2}{4} + (\phi_{x,y}^t - \phi_{x,y-1}^t)^2}}, \quad (104)$$

dále

$$F_i = \frac{\delta t \delta_\varepsilon(\phi_{x,y}^t) \mu(L(\phi^n)) C_i}{h + \delta t \delta_\varepsilon(\phi_{x,y}^t) \mu(L(\phi^n)) (C_1 + C_2 + C_3 + C_4)}, \text{ pro } i = 1, 2, 3, 4 \quad (105)$$

a

$$p_{i,j} = \phi_{x,y}^t - \delta t \delta_\varepsilon(\phi_{x,y}^t) [v + \lambda_1(n_{x,y} - c_1(\phi^n))^2 - \lambda_2(n_{x,y} - c_2(\phi^n))^2] \quad (106)$$

δt je časový krok a h je prostorový krok [37].

4.6.3.1 Reinicializace

Po každé iteraci, kdy je kontura posunuta, je potřeba provést reinicializaci level setové funkce, aby bylo splněno, že pro body patřící kontuře platí $\phi_{x,y} = 0$ a aby nebyla funkce příliš plochá vlivem aproximované funkce δ_ε . Reinicializace probíhá iteračně a je dána diferenciální rovnicí

$$\frac{\partial \phi}{\partial t} = \text{sign}(\phi)(1 - |\nabla \phi|) \quad (107)$$

kde v případě praktické implementace v této práci platí,

$$\text{sign}(\phi) = \frac{\phi}{\sqrt{\phi^2 + |\nabla \phi|}} \quad (108)$$

Při implementaci jsou opět tyto vztahy diskretizovány obdobným způsobem, jako předchozí vztahy, viz. [37].

4.6.3.2 Podmínka ukončení a shrnutí algoritmu

Vývoj aktivní kontury probíhá buďto předem určený počet iterací, nebo dokud není posun kontury příliš malý. Posun kontury je dán vztahem (109).

$$Q = \sum_{|\phi_{x,y}^t|} |\phi_{x,y}^{t+1} - \phi_{x,y}^t| \quad (109)$$

Iterační část algoritmu skončí, pokud $Q < \delta t \cdot h^2$. Kde h je v této práci zvoleno jako $0,18^2$ [38].

Celý algoritmus aktivní kontury Chan Vese tedy čítá následující kroky

1. Inicializace funkce $\phi_{x,y}$.
2. Výpočet c_1 a c_2
3. Výpočet $\phi_{x,y}^{t+1}$ podle (98)
4. Možná reinicializace ϕ .
5. Opakovat body 2-5, dokud není splněna podmínka pro ukončení.

5 FOTOM

Fotogrammetrický program FOTOM začal být vyvíjen v roce 2001 na katedře informatiky Vysoké školy Báňské. Původně měl být využíván v hornictví, konkrétně pro měření důlních jam. Program byl v dalších letech rozšiřován a jeho hlavní doménou se staly medicínské snímky. Až do roku 2008 byl program vytvářen v jazyce C++ a tehdejší verze, *FOTOM 2008*, obsahuje několik modulů:

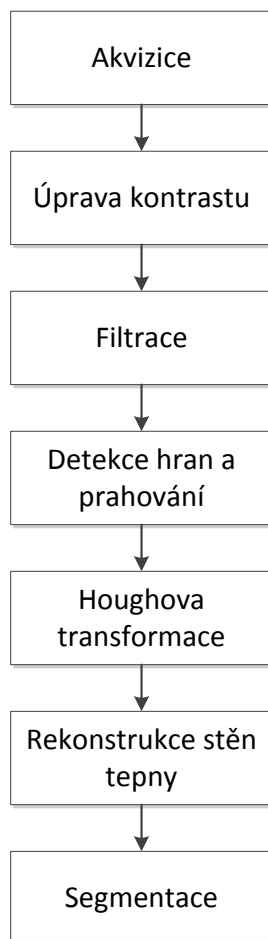
- FOTOM 1 - Hlavní modul slouží pro měření a definování zájmových objektů na snímku, zejména pomocí geometrických primitiv. Dále umožňuje snímky ukládat i s definovanými objekty ve formátu "ftm".
- FOTOM 2 - Úkolem druhého modulu je umožnit dvojrozměrné modelování objektů definovaných na více snímcích. Pomocí vytvořeného modelu lze pak sledovat odchylky mezi jednotlivými objekty.
- FOTOM 3 - Tento modul se zabývá tvorbou trojrozměrných modelů a jejich vizualizací a měřením.
- FOTOM 4 - Modul s číslem 4 je určen k vytváření animací ze série snímků.
- FOTOM 5 - Poslední modul slouží k rozpoznávání objektů.

Významná změna nastala ve verzi FOTOM 2009, kdy již nebyla dostatečná dosavadní struktura programu a celý systém se začal přenášet na modulární platformu NetBeans a do jazyka Java. V této podobě je program vyvíjen doposud pod názvem FOTOM^{NG}.

6 Návrh a realizace

6.1 Automatická detekce

Na následujícím blokovém schématu jsou naznačeny jednotlivé kroky postupu při automatické detekci tepny na ultrazvukovém snímku, který byl navržen v rámci této diplomové práce.



Obrázek 26 Jednotlivé kroky pro automatickou detekci tepny


6.1.1 Akvizice

Akvizice snímků krční tepny probíhá na zařízení pro 3D ultrazvukové měření karotické tepny, které bylo vyvíjeno v letech 2006 až 2008 na Vysoké škole báňské. Zařízení je založeno na automatickém posunu lineární ultrazvukové sondy, kdy jsou získávány dvojrozměrné snímky tepny, z nichž je následně rekonstruován trojrozměrný model tepny i s případným plátem. Mechanická část, která zajišťuje posun a polohování sondy je připevněna k lůžku, na kterém leží vyšetřovaný pacient. Automatický posun sondy je zajištěn krokovým motorem, který umožňuje pohybovat sondou v rozmezí 2-3cm. Jeden krok motoru posune sondu o 0,025mm. Maximální přesnost dosažena při polohování sondy, kdy je vzata do úvahy i vůle závitů, je 0,5mm [40].



Obrázek 27 Akviziční zařízení [40]

Při snímání je důležitým faktorem deformace tepny vlivem činnosti srdce. Ta komplikuje následnou rekonstrukci krční tepny ze snímků. Pro odstranění tohoto vlivu je při měření snímáno i pacientovo EKG, podle kterého je řízen sběr dat, jak je naznačeno na obr. 28.



Obrázek 28 Sběr dat v závislosti na EKG signálu [40]

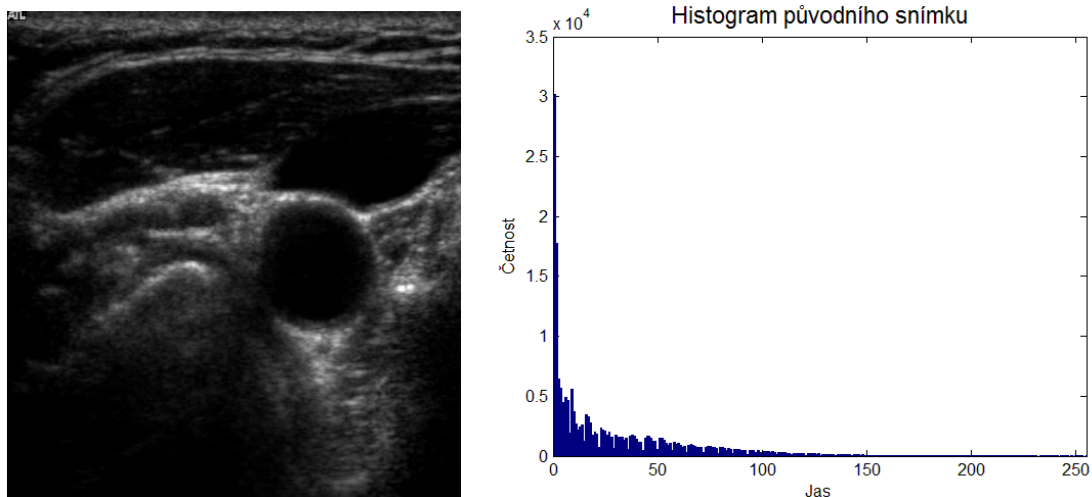
System, který řídí skenování tepny v závislosti na činnosti srdce, je založen na mikrokontroléru ATmega128. Mikrokontrolér je tedy odpovědný za správné časování sejmání obrazu, posun sondy a dynamické přizpůsobení těchto operací podle průběhu EKG signálu. Jako ultrasonograf je v systému využit *GE Vivid 7 Pro* [40].



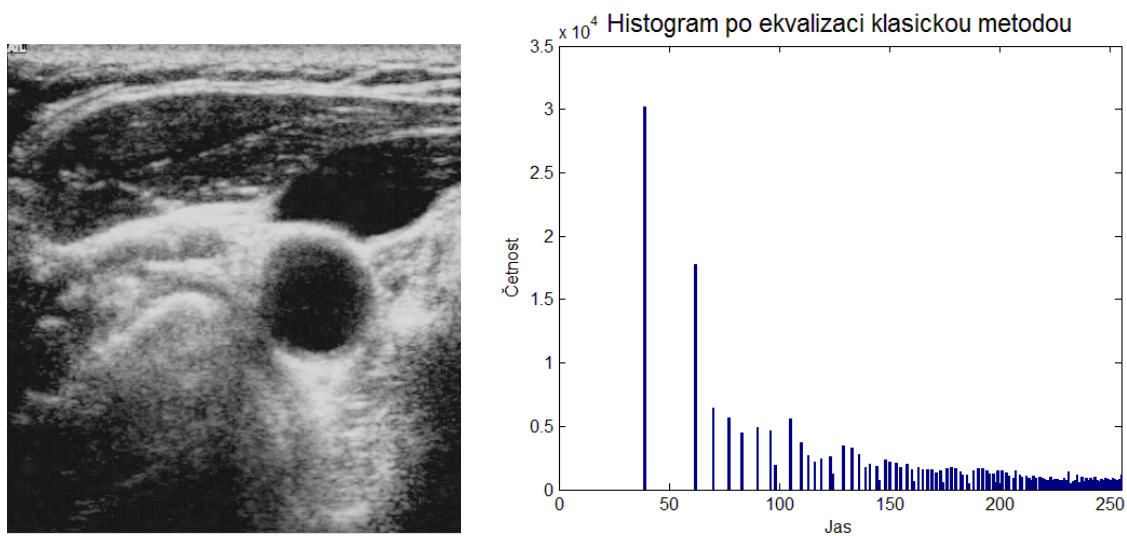
Obrázek 29 Snímání tepny akvizičním zařízením [40]

6.1.2 Úprava kontrastu


I přesto, že je již v ultrasonografu upravován jak dynamický rozsah, tak i v důsledku zesílení všech příchozích ech (Gain) a TGC, jas, je kontrast i jas analyzovaných snímků velmi nízký. Jedním z prvních kroků zpracování je tedy úprava kontrastu snímku.



Obrázek 30 Vlevo původní snímek, vpravo histogram



Obrázek 31 Vlevo snímek po vylepšení kontrastu klasickou metodou, vpravo histogram



Obrázek 32 Vlevo snímek po vylepšení kontrastu metodou CLAHE, vpravo histogram

U metody úpravy kontrastu metodou CLAHE byl snímek rozdělen na 127 částí. Maximální strmost distribuční funkce byla omezena na hodnotu směrnice 3.

Z histogramu původního snímku je patrné, že histogram je velice nevyvážený. Úprava kontrastu klasickou metodou, kdy je snaha linearizovat distribuční funkci, vede i ke zvýšení jasu, kdy, jak je zřejmé, je ve velké míře zesílen i šum. Mnohem lepší výsledek přináší použití metody *CLAHE*, kdy není šum tolik výrazný a naopak jednotlivé struktury jsou více rozlišitelné. Metoda AHE, která byla uvedena v sekci 4.3.1 se z důvodů možnosti CLAHE již téměř nepoužívá, proto zde nebyla ani testována.

6.1.3 Filtrace

Jak bylo uvedeno v části 4.1, existuje široká škála algoritmů pro filtraci ultrazvukových snímků. Pro hodnocení výsledků filtrace lze využít různé metriky, podle kterých lze jednotlivé filtry kvantitativně porovnávat. Jsou to například

$$MAE = \frac{1}{M \cdot N} \sum_{0}^{M-1} \sum_{0}^{N-1} |n_{x,y} - f_{x,y}| \quad (110)$$

$$RMSE = \sqrt{\frac{1}{M \cdot N} \sum_{0}^{M-1} \sum_{0}^{N-1} [n_{x,y} - f_{x,y}]^2} \quad (111)$$

$$SNR = 10 \cdot \log \left[\frac{\sum_{0}^{M-1} \sum_{0}^{N-1} [n_{x,y}]^2}{\sum_{0}^{M-1} \sum_{0}^{N-1} [n_{x,y} - f_{x,y}]^2} \right] \quad (112)$$

$$PSNR = 10 \cdot \log \left[\frac{\max(n_{x,y})^2}{\frac{1}{M \cdot N} \sum_{0}^{M-1} \sum_{0}^{N-1} [n_{x,y} - f_{x,y}]^2} \right] \quad (113)$$

Výčet dalších těchto metrik je uveden např. v [20]. Dále budou uvedeny výsledky filtračních algoritmů implementovaných v této práci.

6.1.3.1 Anizotropně difuzní filtr

Výsledek je při nastaveném počtu 20ti iterací. Hodnota K byla experimentálně zvolena jako 40.



Obrázek 33 Filtrace anizotropně difuzním filtrem

6.1.3.2 Speckle redukující anizotropně difuzní filtr


Výsledek je při zvolení 50ti iterací.



Obrázek 34 Filtrace SRAD filtrem

6.1.3.3 Mediánový filtr


Výsledek při velikosti čtvercového jádra 15x15.



Obrázek 35 Filtrace mediánovým filtrem

6.1.3.4 Mean Shift filtr

Poloměr okolí byl zvolen 6, tolerance rozdílu barvy 30 a uniformní jádro.



Obrázek 36 Filtrace Mean Shift filtrem

6.1.3.5 Výsledky a porovnání filtrů

Použitá metrika	Median	Anis. dif.	SRAD	Mean shift
MAE	9,2605	6,1389	3,778	5,0696
RMSE	24,1947	11,2404	6,1947	9,3118
SNR[dB]	9,1545	15,8132	20,9886	17,4482
PSNR[dB]	20,4564	27,1151	32,29044	28,7501

Tabulka 1 Výsledky jednotlivých filtrů

Z tabulky 1 je patrné, že nejlepšího výsledku dosahuje *Speckle redukující anizotropně difuzní* filtr. Oproti ostatním filtrům má nejvyšší hodnotu SNR a PSNR, naopak jsou nižší hodnoty MAE a RMSE. Podle uvedených metrik, nejhorší výsledky má *mediánový* filtr. Je však potřeba zmínit, že výsledky jsou závislé na použitých parametrech filtrů. Zejména u *mediánového* filtru jsou zde zvoleny velké rozměry jádra, kdy pokud by byla použita menší maska, byly by výsledky příznivější. Uvedené filtry pracují z velké části na rozdílných principech, tedy i s odlišnými nastavitelnými parametry, proto je hodnocení filtrů uvedenými metrikami spíše orientační.


Podle subjektivního hodnocení výsledků se dá souhlasit s výše uvedenými číselnými hodnotami. Pro lepší vizuální zhodnocení byly filtry aplikovány na vstupní neoříznuté snímky. U složitějších filtrů, jako je *SRAD* nebo *Mean shift* jde vidět velmi dobré zachování hran. Důležitější jsou však vlastnosti při dalším počítačovém zpracování snímků. Při testování bylo experimentálně zjištěno, že pro následnou detekci hran a Houghovu transformaci se jeví jako nejvhodnější paradoxně právě *mediánový* filtr.

6.1.4 Detekce hran a prahování

Z vyfiltrovaného obrazu jsou dále zachovány pouze hrany. Detekce hran je provedena klasickým Sobelovým filtrem. Následuje adaptivní prahování iterační metodou, které zachová pouze gradienty s dostatečně velkým modulem. Jelikož jsou tyto operace notoricky známé, nebyly teoreticky popsány v této práci.

6.1.5 Houghova transformace

Pro nalezení tepny v hranovém obraze byla zvolena Houghova transformace. Ačkoliv v praktické části práce byl implementován a testován i algoritmus zobecněné Houghovy transformace, z důvodu problematičnosti s výběrem správných vzorových tvarů a horší detekce, je využívána pouze Houghova transformace pro detekci kružnic.



Obrázek 37 Vlevo snímek po detekci hran, vpravo řez akumulátorem pro $r=55\text{px}$.

Po nalezení maxima akumulátoru se dále pracuje s informací o poloměru nalezené kružnice a jejím středu.

6.1.6 Rekonstrukce stěn tepny


Dalším krokem je příprava obrazu pro segmentaci parametrickou aktivní konturou. Obraz po filtraci mediánovým filtrem je oříznut okolo nalezeného středu tak, aby pro další zpracování zůstalo pouze blízké okolí tepny. Následně je takový obraz prahován adaptivní iterační metodou, tentokrát však s upravenou hranicí prahu posunutou o hodnotu jasu 10 směrem do vyšších hodnot intenzity. Tato hodnota byla zvolena experimentálně. Následně jsou detekovány hrany.



Obrázek 38 Vlevo vyhlazený snímek po oříznutí a prahování, uprostřed po detekci hran, vpravo po rekonstrukci stěn tepny

Na většině analyzovaných ultrazvukových snímků tepny se projevuje artefakt akustického stínu, zejména v přítomnosti kalcifikovaného plátu v horní části arterie. V takovém případě chybí informace o velké části stěny tepny, což má za následek nechtěný vývoj kontury mimo oblast zájmu. Z pohledu parametrických aktivních kontur, za předpokladu využití externí energie podle vztahu (53), je možné do jisté míry zabránit úniku kontury pomocí zvolení větší tuhosti modelu. S větší tuhostí se však zhoršují vlastnosti kontury při modelování konkávních oblastí, zejména v okolí plátu. Při využití *GVF* jako vnější energie jsou hrany, které vznikají v důsledku akustického stínu na pokrajích stěn tepny, zdrojem sil, které vytahují konturu mimo zájmovou oblast. Je tedy nezbytné chybějící část stěny arterie rekonstruovat. Pro tento úkol je využit algoritmus, který hranový obraz převede do polárních souřadnic, kdy se jako počátek uvažuje střed nalezené kružnice. V potaz je brána vždy nejmenší vzdálenost pro daný úhel.


Následně jsou zvoleny dvě hodnoty, jedna je práh t pro maximální vzdálenost, kdy ještě nebude doplněna stěna tepny, a dále vzdálenost, do které se doplní nové pixely, pokud není pro daný úhel nalezena stěna. První hodnota je experimentálně zvolena jako $t = r + 4$, kde r je poloměr nalezené kružnice v pixelech. Druhá hodnota byla zvolena rovno r . Funkce algoritmu je naznačen na obr. 39.



Obrázek 39 Znárodnění algoritmu pro rekonstrukci tepny


6.1.7 Segmentace

Pro segmentaci vnitřní oblasti tepny je využita parametrická aktivní kontura s GVF jako vnější silou. Parametry kontury jsou $\alpha = 1$, $\beta = 0$, $\delta t = 0,5$, počet iterací výpočtu GVF je 50, μ je 0,1, kde význam těchto údajů byl popsán v podkapitole 4.4. Počáteční kontura je umístěna do nalezeného středu a její poloměr je 25 pixelů.



Obrázek 40 GVF pole pro segmentaci s naznačením umístění iniciální kontury


Výsledkem segmentace je kontura, která určuje vnitřní stěnu tepny. Při bezchybném určení obrysu tepny je potom možné určit obsah a velikost plátu pomocí rozdílu nalezeného obrysu tepny a kontury.




Obrázek 41 Výsledný polygon po segmentaci stěny tepny

Segmentace geometrickou aktivní konturou Chan Vese, která byla v rámci této práce implementována, nakonec nebyla při analýze karotické tepny využita, jelikož metody parametrické aktivní kontury se ukázaly jako zcela dostačující.

Ačkoliv tedy segmentace metodou Chan Vese nebyla využita, lze ji použít v systému *FOTOM* při segmentaci jiných snímků. Na následujících záznamech z magnetické rezonance je demonstrována funkčnost implementovaného algoritmu a jeho výhody, tedy nezávislost na hranách objektů a možná změna topologie.



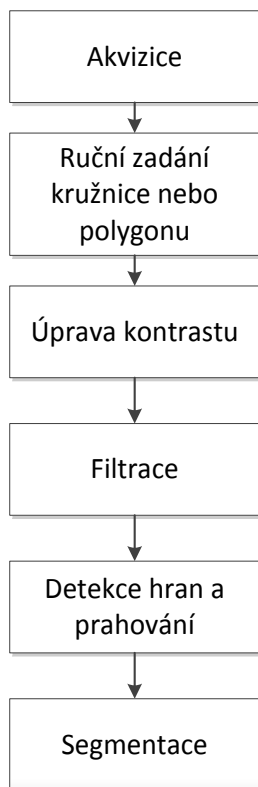
Obrázek 42 Segmentace tumoru metodou Chan vese. Původní snímek získán z [41]



Obrázek 43 Segmentace tumoru metodou Chan vese. Původní snímek získán z [39]

6.2 Poloautomatická detekce

Jak je patrné dále z kapitoly 7, algoritmus automatické detekce nemusí vždy tepnu správně nalézt. V takovém případě je možné využít poloautomatické detekce, kdy lze ručně zadat oblast vnější stěny tepny. Ruční zadání obrysu arterie je možné provést pomocí kružnice nebo polygonu. Segmentace vnitřní oblasti je pak již vykonána automaticky.




Obrázek 44 Jednotlivé kroky při poloautomatické detekci tepny

Kroky akvizice, filtrace, detekce hran, prahování a segmentace jsou stejné jako u automatické detekce. Při poloautomatické detekci odpadá logicky nutnost provedení Houghovy transformace pro nalezení tepny a do jisté míry je také zjednodušena rekonstrukce chybějících stěn tepny. V situaci, kdy vlivem artefaktů chybí informace o části stěny arterie, je tato doplněna ručně zadaným tvarem, čímž se také zlepší přesnost segmentace vnitřní oblasti tepny.

6.3 Tvorba 3D modelu

V rámci práce byl zpracován algoritmus pro tvorbu 3D modelu tepny, který však po domluvě s vedoucím práce prozatím nebyl implementován do systému FOTOM^{NG}. Model je vytvořen z nalezených kontur určujících vnitřní oblast tepny.



Obrázek 45 Část 3D modelu rekonstruované tepny


K 3D modelování je využita třída *TriangleStripArray* z *Java3D API*. Ta propojuje jednotlivé dvourozměrné kontury pomocí pole trojúhelníkových ploch, pro které jsou definovány parametry určující vzhled povrchu.

Každý polygon je redukován na 360 voxelů, kdy v každém úhlu vzhledem ke středu nalezené tepny je definován jeden voxel.

6.4 Zařazení do systému FOTOM^{NG}

Pro implementaci funkce detekce tepny do programu FOTOM^{NG} byl vytvořen nový modul platformy NetBeans, který obsahuje všechny potřebné funkce pro automatickou detekci a následnou segmentaci. Navíc je vytvořen další modul, který poskytuje nástroje pro poloaautomatickou detekci a segmentaci.

Funkce automatické detekce tepny byla v GUI umístěna na hlavní lištu programu.



Obrázek 46 Zařazení algoritmu na hlavní lištu


Jelikož tento proces může zejména na starších počítačích trvat několik sekund, během které se GUI nepřekresluje, probíhají operace detekce tepny v samostatném vlákne pomocí třídy *SwingWorker*, která zajišťuje funkčnost programu i během výpočtu. Pro sledování průběhu výpočtu je pomocí modulu *Progress API* a *Progress UI*, které jsou poskytovány platformou, přidán na dolní lištu ukazatel průběhu.



Obrázek 47 Progress bar při detekci tepny


Po dokončení výpočtů jsou definovány dva objekty tříd, které byly vytvořeny panem Ing. Krahulcem [42] v minulých letech. Jeden je objekt třídy *CircleTool*, jež určuje nalezený obrys

tepny a druhý třídy *PolygonTool*, což je kontura určující vnitřní oblast tepny. Obě zmíněné třídy jsou potomky třídy *ShapeTool*. Jedná se tedy o nástroje pro definování objektů a zájmových oblastí na snímku. Po vytvoření jsou odkazy na tyto objekty automaticky umístěny v *Manažeru objektů*.




Obrázek 48 Nalezené objekty jsou zařazeny do Manažeru objektů, kde s nimi lze dále pracovat

Po označení obou objektů v *Manažeru objektů* byla do systému implementována funkce pro zobrazení rozdílu obsahů mezi těmito objekty v pixelech. Pokud jsou pro snímek definovány vlíčovací body, je zobrazen i reálný rozdíl obsahů, tedy případná plocha řezu sklerotického plátu.



Obrázek 49 Zobrazení rozdílu plochy dvou objektů

Pro spuštění poloautomatické detekce jsou využity výše zmíněné objekty systému *FOTOM^{NG}*, implementované Ing. Krahulcem. Po jejich definování na snímku je jim přidána akce "*najdi tepnu*", která je zobrazena po kliknutí pravým tlačítkem na objekt.



Obrázek 50 Možnost spuštění poloautomatické detekce tepny


Podrobnější popis, jak využít tyto nástroje je uveden v uživatelské příručce v příloze.

Stejně jako u ostatních modulů systému, i tyto využívají pro většinu jednodušších operací zpracování obrazu *Java Advanced Imaging (JAI) API*. Je to například použití mediánového filtru, logické operace nebo oříznutí obrazu.

Pro výpočetně náročnější matematické operace, jako je například určení inverzní matice při *GVF*, je využita knihovna *Commons Math*.

7 Výsledky

Stejně jako subjektivní vyhodnocení ultrazvukových snímků, i zde implementované algoritmy pro detekci a analýzu karotické tepny jsou závislé především na kvalitě naměřených dat. Ačkoliv systém pro akvizici snímků (viz sekce 6.1) přináší mnoho výhod pro další zpracování, chybí u něj funkce doladování parametrů ultrasonografu, které při běžném měření provádí člověk v závislosti na aktuální kvalitě obrazu a rozlišitelnosti objektu. Dalším problémem v důsledku snímání tepny pomocí mechanického zařízení je občasné stlačování tepny sondou, a tedy její deformace na snímku. To významně znesnadňuje automatické nalezení tepny a správné označení její stěny pomocí algoritmu automatické detekce.




Obrázek 51 Ukázka výsledku navrženého algoritmu pro detekci tepny

7.1 Automatická detekce tepny


Algoritmus pro automatické nalezení tepny je nejvíce závislý na okolních strukturách v obraze, které mohou mít částečně kruhový tvar. V takovém případě, pokud je zároveň objekt tepny málo zřetelný, dochází k chybné detekci objektu.

Testováno bylo celkem 1100 snímků získaných z několika naměřených videí z akviziční jednotky. Arterie byla úspěšně nalezena na 870 snímcích. Na 230 snímcích byla tepna detekována nesprávně. Procentuální úspěšnost je uvedena na obr. 52.




Obrázek 52 Úspěšnost automatického nalezení tepny

Správná detekce byla při testování významně závislá na čase, kdy úspěšnost s postupujícím časem, a tedy i posunem, prudce klesala. Vzhledem k povaze testovaných snímků je zřejmé, že se tomu tak děje z důvodu *rozladování* ultrasonografu. Na začátku měření je sonda umístěna lékařem tak, aby byla tepna na snímcích co nejvíce zřetelná. V těchto okamžicích detekce dosahuje úspěšnosti až sto procent. Často ani přítomnost větších kalcifikovaných sklerotických plátů nevede k větší chybovosti detekce. Postupem času, jak je sonda automaticky posouvána, vizuální kvalita objektu klesá a s ní i detekční schopnosti algoritmu. Tento průběh je naznačen na obr. 53 a 54, kde jsou uvedeny grafy s procentuální úspěšností detekce v závislosti na čase a posunu sondy, pro dvojce měření.



Obrázek 53 Sloupkový graf s procentuální četností správné detekce v závislosti na čase pro jednu sérii dat




Obrázek 54 Sloupcový graf s procentuální četností správné detekce v závislosti na čase pro druhou sérii dat

7.2 Segmentace při automatické a poloautomatické detekci

Pokud je tepna správně nalezena, pokračuje algoritmus v segmentaci vnitřní oblasti tepny. Jelikož při automatické detekci se předpokládá kruhový tvar, je algoritmus dosti náchylný na její stlačování sondou. Příčinou dalších nepřesností je zejména proces nezbytné rekonstrukce stěny tepny. Zde je však třeba poznamenat, že paralelně s touto prací je na VŠB v rámci jiné diplomové práce vyvíjen algoritmus, který zajistí zkvalitnění objektu tepny na snímcích a případnou sofistikovanější rekonstrukci chybějících částí stěn arterie za pomoci informací z v čase předchozích snímků. V takovém případě by bylo dosaženo výrazně lepších výsledků, zřejmě srovnatelných s výsledky poloautomatické detekce.

Výsledky segmentace byly porovnávány s ručně vyznačenými stěnami arterie. Ty byly vyznačeny buďto přímo lékařem, nebo na základě jejich zaškolení ve vyhodnocování těchto snímků. Vyhodnocování statických ultrazvukových záznamů je v mnoha případech velmi subjektivní. Často nejde jasně odlišit plát od šumu, a dosti tak závisí na zkušenostech lékaře. Dalším znesnadňujícím faktorem je skutečnost, že během klasického vyšetření si obsluhující lékař při nejednoznačnostech může měnit parametry ultrasonografu, jako je zesílení, frekvence apod., což na statických záznamech není možné. Je tedy nutné vycházet pouze z omezené informace při jednom nastavení. I přes tyto skutečnosti byly ručně označené oblasti brány jako správné a tedy referenční při měření odchylek vzhledem k automatické segmentaci. Měřena byla plocha v mm^2 , která se nepřekrývala s referenčními oblastmi. Ačkoli se nemuselo jednat pouze o oblasti plátu, byly tyto odchylky zaznamenány, a to hlavně z důvodu, že *FOTOM* umožňuje nejsnadněji měřit plochu plátů pomocí rozdílu obsahů dvou oblastí, tedy oblasti obrysu tepny a vnitřní oblasti tepny. Výsledky z 60ti snímků jsou shrnuty na obr. 55. Tabulka s výsledky je umístěna v příloze.



Obrázek 55 Krabicové grafy chyb detekcí

Jak je tedy patrné, pomocí poloautomatické detekce je dosaženo výrazně přesnějších výsledků. Průměrná hodnota špatně označené plochy u automatické detekce je $2,816\text{mm}^2$ s rozptylem $2,593\text{mm}^4$ kdežto u poloautomatické detekce je průměrná hodnota $1,105\text{mm}^2$ a rozptyl $0,585\text{mm}^4$. Vzhledem k tomu, že práce s objekty, jako je kružnice nebo polygon, případné vzájemné převádění mezi těmito typy objektů, je v systému *FOTOM*^{NG} snadná a rychlá, je i při poloautomatické detekci ušetřen čas vyšetřujícího, který by jinak musel označit plát ručně.

8 Závěr

Cílem této práce bylo navrhnout a realizovat takový modul systému FOTOM^{NG}, který umožňuje nalézt a rekonstruovat karotickou tepnu z ultrazvukových snímků (B - zobrazení, příčný řez) s případnými sklerotickými pláty.

Mým prvním krokem před samotným zpracováním zadaného problému bylo důkladné seznámení se s jazykem Java a platformou NetBeans, na které je systém FOTOM^{NG} postaven, a do které má být mnou realizovaný návrh implementován ve formě přídatného modulu.

Z důvodu specifických vlastností ultrazvukových snímků jsem se musel dále seznámit se vznikem těchto obrazů a s tím spojeným chováním ultrazvukových vln v lidské tkáni a jejich následným zpracováním v ultrasonografu. Po pochopení těchto principů jsem mohl přistoupit k výběru metod, které by nejvhodněji řešily zadanou úlohu.

Při návrhu řešení jsem se nejdříve zaměřil na registrační algoritmy, které by umožnily nalézt požadovaný objekt v obraze. Během dalšího postupu se však ukázalo, že zejména z důvodu časové náročnosti a ne vždy uspokojivému výsledku multimodálních optimalizačních úloh, není tento postup pro praktické využití aplikace vhodný. Následně jsem navrhl postup pro detekci požadovaného objektu, který je podrobněji popsán v této práci.

Samotný návrh se skládá z několika dílčích úloh analýzy obrazu, které je možné řešit více způsoby. Během práce bylo pro každou zmíněnou část realizováno a testováno několik metod, z nichž jsem do výsledného modulu implementoval jen ty nejvhodnější. Nevyužité, avšak úspěšně implementované metody, lze v budoucnu použít při řešení jiných problémů. Větší prostor v práci jsem věnoval filtraci ultrazvukových snímků a popisu specifického *speckle* šumu, který znesnadňuje další kroky analýzy, a pro jehož odstranění nebo potlačení existuje několik různorodých postupů. Další významná oblast zpracování obrazu, kterou jsem se ve své práci zabýval, jsou parametrické a geometrické aktivní kontury. Zejména parametrické aktivní kontury se ukázaly jako nejvhodnější pro segmentaci daného objektu. Na samotné nalezení tepny v obraze byla využita metoda Houghovy transformace pro detekci kružnic, která poskytuje rychlý výsledek, jehož úspěšnost detekce při testování dosáhla 79,1%.

I přesto, že výsledná automatická detekce objektu je z velké části úspěšná a průměrná chybně označená plocha segmentace při testování byla $2,82\text{mm}^2$, rozhodl jsem se navíc realizovat metodu poloautomatické detekce tepny, která by usnadnila segmentaci objektu při jeho nesprávné detekci. V této metodě jsem umožnil uživateli označit si oblast karotické tepny na snímku manuálně, a následně již nechat program ohraničit vnitřní oblast tepny pomocí segmentačních algoritmů. Manuální označení lze provést jak pomocí kružnice, tak využít polygon s libovolným počtem vrcholů. Díky tomu se snižuje plocha chybně označené oblasti segmentace, a to zejména v případě stlačené tepny.

Po realizaci všech uvedených kroků algoritmu jsem implementoval modul do programu FOTOM^{NG} tak, aby pokud možno co nejvíce využíval v systému již existující nástroje a díky tomu mohl využít i možnosti tohoto systému v oblasti fotogrammetrie. Potom lze jednotlivé

nalezené objekty proměřovat a snadno tak analyzovat vývoj aterosklerotických plátů na snímcích.

Přesto, že výsledky prezentované v sedmé kapitole, kterých bylo dosaženo při testování navrženého nástroje, lze považovat za příznivé, je tu stále prostor pro další vylepšení. Pro úspěšnější detekci by bylo vhodné upravit algoritmus pro rekonstrukci snímků zatížených artefaktem akustického stínu pomocí informace z předchozích obrazů. Lepší výsledky by také přinesla automatická konfigurace ultrasonografu během akvizice.

Jelikož jsou snímky pořízeny na přístroji určeném pro trojrozměrnou analýzu arterie, pomocí realizovaného algoritmu automatické detekce tepny tak lze snadno vytvořit 3D model tepny bez nutnosti zásahu uživatele. Pro sestavení jednoduchého 3D modelu jsem využil Java3D API. Po uvážení však tento nástroj nebyl doposud implementován do systému, a v dalších letech mu bude věnován samostatný modul.

Díky modulu realizovaném v této práci umožňuje systém FOTOM^{NG} provádět časově nenáročnou analýzu ultrazvukových snímků karotické tepny a to ať už pomocí automatické nebo poloautomatické detekce. V kombinaci se zařízením pro akvizici těchto snímků, které bylo vyvinuto na VŠB-TU Ostrava v minulých letech, se tak FOTOM^{NG} stává unikátním nástrojem pro vyšetření aterosklerotických plátů v karotických tepnách.

9 Použitá literatura

- [1] ČÍHÁK, Radomír. *Anatomie III*. 1. vyd. Praha: Grada, 1997, 672 s. ISBN 80-7169-140-2
- [2] Ateroskleróza. In: *Vitalion* [online]. 2012 [cit. 2013-03-10]. Dostupné z: <http://nemoci.vitalion.cz/ateroskleroz/>
- [3] STRÍTESKÝ, Jan. *Patologie*. Vyd. 1. Olomouc: Epava, 2001, 338 s. ISBN 80-862-9706-3.
- [4] LOIZOU, C. *Ultrasound image analysis of the carotid artery*. London, 2005. Dostupné z: http://www.medinfo.cs.ucy.ac.cy/doc/Publications/PhD/CLoizou/PhD_CLoizou.pdf. Disertační práce. Kingston university, School of Computing and Information Systems.
- [5] ZUNA, Ivan a Lubomír POUŠEK. *Úvod do zobrazovacích metod v lékařské diagnostice*. 1. vyd. Praha: Vydavatelství ČVUT, 2002, 76 s. ISBN 80-010-2152-1.
- [6] SZABO, Thomas L a Lubomír POUŠEK. *Diagnostic ultrasound imaging: inside out*. 1. vyd. Boston: Elsevier Academic Press, c2004, xxii, 549 p. ISBN 01-268-0145-2.
- [7] FARAN, J. J. Sound scattering by solid cylinders and spheres. *Journal of the Acoustical Society of America*. United States of America: Acoustical Society of America, 1951, č. 23, s.405-418. ISSN 0001-4966. DOI: <http://dx.doi.org/10.1121/1.1906780>.
- [8] ANDERSON, M.E. a G.E. TRAHEY. A seminar on k-space applied to medical ultrasound. In: *Virtual Imaging Laboratory: Duke University* [online]. 2006 [cit. 2013-03-10]. Dostupné z: <http://dukemil.bme.duke.edu/Ultrasound/k-space/index.htm>
- [9] ALI, M., D. MAGEE a U. DASGUPTA. Signal Processing Overview of Ultrasound Systems for Medical Imaging. In: *Texas Instruments* [online]. 2008 [cit. 2013-03-10]. Dostupné z: <http://www.ti.com/lit/wp/sprab12/sprab12.pdf>
- [10] TUTHILL, T.A., R.H. SPERRY a K.J. PARKER. Deviations from Rayleigh statistics in ultrasonic speckle. *Ultrasonic imaging*. 1988, roč. 1988, č. 10, s. 81-89.
- [11] LEE, J.S. Digital image enhancement and noise filtering by use of local statistics. *IEEE Trans. on Pattern Analysis and Machine Intelligence*. 1980, roč PAMI-2, č.2., s. 165-168.
- [12] HRAZDIRA, I. Úvod do ultrasonografie v otázkách a odpovědích. Brno : LF MU, 2008. 11 s.
- [13] LEE, J.S. Refined filtering of image noise using local statistics. *Computer Graphic Image Proceseing*. 1981, roč. 15, s. 380-389.
- [14] FROST, V.S., K.S. STILES a J.C. HOLTZMAN. A model for radar images and its application for to adaptive digital filtering of multiplicative noise. *IEEE Trans. on Pattern Analysis Mach. Intellig*. 1981, roč. PAMI-4, č.2, s. 157-165.

- [15] KUAN, D.T. a A.A. SAWCHUCK. Adaptive noise smoothing filter for images with signal dependent noise,. *IEEE Trans. on Pattern Analysis and Mach. Intellig.* 1985, roč. PAMI-7, č.2, s. 165-177.
- [16] LOPES, A., E. NEZRY, R. TOUZI a H. LAUR. Maximum A posteriori speckle filtering and first order texture model in SAR images. *Proc. of the Int. Geoscience and Remote Sensing Symposium (IGARSS'90)*. 1990, s. 2409-2412.
- [17] HAIDEKKER, Mark. *Advanced Biomedical Image Analysis*. Singapoure: Wiley, 2010. 1. ISBN 978-0470624586.
- [18] PERSONA, P. a J. MALIK. Scale-space and edge detection using anisotropic diffusion. *IEEE Trans. Pattern Anal. and Mach. Intellig.* 1990, roč. 12, č.7, s. 629-639.
- [19] YONGJIAN, Y. a S.T. ACTON. Speckle reducing anisotropic diffusion. *IEEE Trans. on Image Proces.* 2002, roč. 11, č. 11, s. 1260-1270.
- [20] SIVAKUMAR, R., M.K GAYATHRI a D. NEDUMARAN. Speckle Filtering of Ultrasound B-Scan Images: A Comparative Study of Single Scale Spatial Adaptive Filters, Multiscale Filter and Diffusion Filters. *IACSIT international journal of engineering and technology (IJET)*. 2010, roč. 2, č. 6. ISSN 1793-8236.
- [21] WEICKERT, Joachim. *Anisotropic diffusion in image processing*. Stuttgart: B.G. Teubner, 1998. ISBN 978-351-9026-068.
- [22] JAN, Jiří. *Medical image processing, reconstruction and restoration: concepts and methods*. Boca Raton: Taylor, 2006, 730 s. ISBN 08-247-5849-8.
- [23] TOENNIES, Klaus D. *Advanced Biomedical Image Analysis: Methods and Algorithms*. Magdeburg: Springer, 2012. 2012. ISBN 978-1447127505.
- [24] BLACK, M.J., G. SAPIRO, D.H. MARIMOUNT a D. HEGER. Robust Anisotropic Diffusion. *IEEE Trans. on Image Proces.* 1998, roč. 7, č. 3, s. 421-432.
- [25] CANNY, J. A Computatuonal Approach to Edge Detection. *IEEE Trans. Pattern Anal. Machine Intell.* 1986, PAMI-8, s. 679-698.
- [26] DOUBEK, Petr. Mean-Shift segmentace. 29.10.2007 [cit. 2013-02-03]. Dostupné z WWW: <http://cmp.felk.cvut.cz/cmp/courses/ZS1/Cviceni/cv4/meanshift.pdf>.
- [27] ACHARYA, Tinku. *Image processing: principles and applications*. Hoboken,: John Wiley, 2005, xx, 420 s. ISBN 978-0-471-71998-4.
- [28] Adaptive histogram equalization. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2001- [cit. 2013-03-17]. Dostupné z: http://en.wikipedia.org/wiki/Adaptive_histogram_equalization
- [29] PIZER, S.M., E.P. AMBURN a J.D. AUSTIN. Adaptive Histogram Equalization and Its Variations. *Computer Vision, Graphics, and Image Processing*. 1987, č. 39, s. 355-368.

- [30] KASS, M., A. WITKIN a TERZOPOULOS. Snakes: Active Contour Models. *International Journal of Computer Vision*. 1988, 1., s. 321-331.
- [31] IVINS, J a J. PORRILL. Everything you always wanted to know about snakes: But were afraid to ask. *AIVRU Technical Memo*. 1993, č. 86.
- [32] C. Xu and J. L. Prince, "Gradient vector flow: A new external force for snakes," in *IEEE Proc. Conf. on Computer Vision and Pattern Recognition*, 1997, s. 66–71.
- [34] XU, Ch. *Snake, Shapes and Gradient Vector flow*. *IEEE Transaction on Image Processing*, 1998; 7, s. 359-369.
- [35] CHAN, T.F. a L.A. VESE. Active Contours Without Edges. *IEEE Trans. on Image Proces.* 2001, roč. 10, č. 2, s. 266-277.
- [36] OSHER, Stanley a Ronald P FEDKIW. *Level set methods and dynamic implicit surfaces*. New York: Springer, c2003, xii, 273 s. Applied mathematical sciences (Springer-Verlag New York Inc.), v. 153. ISBN 03-879-5482-1.
- [37] CRANDALL, R. Image Segmentation Using the Chan-Vese Algorithm. *The University of Arisona* [online]. 2009, s. 23 [cit. 2013-03-14]. Dostupné z: http://math.arizona.edu/~rcrandall/ECE532_ProjectPaper.pdf
- [38] PDE - Based Image Segmentation. In: WU, Y. *Rex's Tribe of Image Processing* [online]. 2009 [cit.2013-03-17]. Dostupné z: <https://sites.google.com/site/rexstribeofimageprocessing/Home>
- [39] *MRI Scan A Visible look at what's Growing on Ron's Brain* [online]. 2012 [cit. 2013-03-17]. Dostupné z: <http://prayforroncuellar.blogspot.cz/2012/05/mri-scan-visible-look-at-whats-growing.html>
- [40] LIČEV, L., J. ŠKUTA, M. KRUMNIKL, M. BABIUCH a R. FARAN. *Device for Positioning the Ultrasound Probe during the Carotid Artery Examination*. VŠB Technical University of Ostrava, 2012, 4 s.
- [41] GAILLARD, F. Ganglioglioma of the occipital lobe. In: *Radiopaedia* [online]. 2008 [cit. 2013-03-17]. Dostupné z: <http://radiopaedia.org/images/5651>
- [42] KRAHULEC, L. *Počítačové zpracování fotografie*. Ostrava, 2009. Diplomová práce. VŠB Technická Univerzita. Vedoucí práce doc. Ing. Lačezar Ličev, CSc.
- [43] *Ateroskleróza. Příznaky nemoci* [online]. 2013 [cit. 2013-04-08]. Dostupné z: <http://www.priznakynemoci.com/ateroskler%C3%B3za>

10 Seznam příloh

Příloha 1 - Tabulka naměřených odchylek při automatické a poloautomatické detekci

10.1 Přílohy uložené na DVD

- Zdrojové kódy
- Program FOTOM^{NG}
- Programátorská příručka ve formě Javadoc
- Uživatelská příručka
- Snímky použité při testování

Příloha 1 - Tabulka naměřených odchylek segmentace při automatické a poloautomatické detekci

	<i>Poloautomatická detekce</i>		<i>Automatická detekce</i>	
Číslo snímku	Odchylka[px]	Odchylka[mm ²]	Odchylka[px]	Odchylka[mm ²]
000	72	0.523	172	1.274
000b	373.5	2.814	468	3.467
010	309	2.290	432	3.200
010b	137	1.015	495.5	3.670
020	209	1.548	476.5	3.530
020b	631	4.674	836	6.193
30	98	0.726	558	4.133
30b	241	1.785	420	3.111
40	93	0.689	453	3.356
40b	146	1.081	545	4.037
50	137	1.015	559	4.141
50b	133	0.985	996	7.378
60	106	0.785	486	3.600
60b	171	1.267	503	3.726
70	59	0.437	220	1.630
70b	164	1.215	313	2.319
80	280	2.074	317	2.348
80b	38	0.281	575	4.259
90	123.5	0.915	102	0.756
90b	75	0.556	614	4.548
100	130	0.963	89	0.659
100b	201	1.489	125	0.926
110	178	1.319	204	1.511
110b	103	0.763	767	5.681
120	70	0.519	607	4.496
120b	309	2.289	603	4.467
130	121	0.896	109	0.807
130b	74	0.548	848	6.281
140	115	0.852	432	3.200
140b	127	0.941	143	1.059
150	225	1.667	55	0.407
150b	240	1.778	494	3.659
160	198	1.467	316	2.341
160b	83	0.615	192	1.422
170	137	1.015	385	2.852
170b	274	2.030	254	1.881
180	119	0.881	325	2.407

180b	180	1.333	126.4	0.936
190	151	1.119	317	2.348
190b	9.5	0.070	101	0.748
200	126	0.933	359	2.659
205b	20.5	0.152	226	1.674
210	67	0.496	275.5	2.041
210b	26	0.193	175	1.296
220	146	1.081	337	2.496
220b	49	0.363	316	2.341
230	123	0.911	566	4.193
230b	100	0.741	352	2.607
240	285	2.111	659	4.881
250	205	1.519	424	3.141
260	256	1.896	544	4.030
270	150	1.111	409	3.030
280	110	0.815	716	5.304
290	171	1.267	277	2.052
300	119	0.881	202	1.496
300b	12	0.089	93	0.689
310b	63	0.467	198	1.467
320b	15	0.111	19	0.141
330b	116	0.859	253	1.874